



**Diogo Antunes  
Gonçalves**

**Modelação da Secagem de Papel "tissue" em  
Ambiente Industrial**





**Diogo Antunes  
Gonçalves**

**Modelação da Secagem de Papel "tissue" em  
Ambiente Industrial**

Dissertação apresentada à Universidade de Aveiro para cumprimento dos requisitos necessários à obtenção do grau de Mestre em Engenharia Mecânica, realizada sob orientação científica do Prof. Doutor Nelson Amadeu Dias Martins, Professor Auxiliar do Departamento de Engenharia Mecânica da Universidade de Aveiro.



“Todo lo que puedas imaginar es real”  
Picasso

Aos meus pais.



## **O júri / The jury**

Presidente / President

**Prof. Doutora Mónica Sandra Abrantes de Oliveira Correia**

Professora Auxiliar do Departamento de Engenharia Mecânica da Universidade de Aveiro

Vogais / Committee

**Prof. Doutor Nelson Amadeu Dias Martins**

Professor Auxiliar do Departamento de Engenharia Mecânica da Universidade de Aveiro (orientador)

**Prof. Doutor Luís António da Cruz Tarelho**

Professor Auxiliar do Departamento de Ambiente e Ordenamento da Universidade de Aveiro





## **Agradecimentos / Acknowledgements**

Agradeço ao Prof. Doutor Nelson Martins, pela disponibilidade, pelo exemplo, pelo apoio académico e pela motivação. Pela oportunidade de ter sido seu orientando desde o tempo das Bolsas de Integração à Investigação e por um dia me ter dito: “Parece ambicioso mas... vale a pena tentar”;

À GALP, a mentora do programa de estágios GALP 20-20-20, que me facultou a hipótese de estagiar com total liberdade, de modo a obter o que desejava enquanto Dissertação;

À AMS-Gomá Camps, a empresa que me acolheu. Agradeço a todos, com especial carinho a todos aqueles que me apoiaram no desenvolvimento desta Dissertação. Não fui fácil de aturar, eu sei, e agradeço a disponibilidade. Ao João Paulo por “ Se algum dia tiver um filho tão chato como tu, chamo-lhe Diogo!”;

À Toscotec, pelo apoio técnico que recebi durante o estágio;

Ao meu amigo, João Costa, pela paciência em me ajudar com os meus problemas em MATLAB®; À minha amiga Diana pela paciência em rever uma dissertação que nada lhe diz;

À minha família e aos meus amigos, porque sem eles nada disto faria sentido. Obrigado pela força e pelos melhores momentos da minha vida;

A todos, muito Obrigado.



## Palavras-chave

Modelo de Secagem; Papel *tissue*; Redes Neurais

## Resumo

Tendo em conta os elevados custos relativos à secagem, é de certa forma interessante, se não mesmo, mandatório, que se invista na modelação deste tipo de processos. Através do desenvolvimento de um modelo de secagem, é possível operar e evoluir no sentido da eficiência energética.

Transversalmente a todo o tipo de indústrias, modelos analíticos para a modelação de processos de secagem têm vindo a ser desenvolvidos e implementados. A utilização do conceito de *softcomputing*, como é o caso das Redes Neurais, ainda se encontra pouco disseminado para a introdução de modelos em ambiente industrial.

No presente trabalho, foram utilizadas Redes Neurais, através do MATLAB®, para a criação e implementação do modelo. Foram definidas as variáveis relevantes para a criação de um modelo e, a partir destas, foi construída uma base de dados. O modelo desenvolvido, revelou obter convergência de valores com elevada certeza.

A arquitetura do modelo era constituída por uma camada oculta, com 4 neurónios associados e treinada através do algoritmo Bayesian Regularization. O erro percentual foi de cerca de 0.00008 % com  $R=1$ .

Foi complementado o modelo de secagem, com um modelo de consumos e foi desenvolvida uma aplicação capaz de: criar, treinar, e utilizar diferentes condições de secagem, com possível comparação de consumos e os seus custos específicos.

Através da análise do modelo, foi possível perceber-se quais os intervenientes mais eficientes da secagem, tendo em conta, o paradigma energético atual.



**Keywords**

Drying Model; tissue paper, Neural Networks

**Abstract**

Taking into account the energy costs related to drying processes, it becomes interesting, or even mandatory, that companies invest in developing drying models. Throughout the implementation of these models, it is possible to operate and evolve towards energy efficiency.

Widely spread in all industries, there are being developed and implemented analytical drying models. However, the uses of softcomputing tools, such as, Neural Networks, are still not spread into industrial based models.

In this work, it was used Artificial Neural Network toolbox from MATLAB® in order to develop and implement a drying model. After studying the relevant variables, it was built a database to feed the model. The drying model showed to have a strongly converging behaviour.

The model's architecture is a Feed Forward Neural Network, with 1 single hidden layer, 4 neurons and trained with Bayesian Regularization. The obtained MAPE is around 0.00008 % with  $R=1$ .

An energy consumption model was created and correlated to the drying model. This allowed the development of an application able to: create, train and use different drying parameters, with the power to compare different energy consumption scenarios and its specific costs.

Analising the created drying model, it was possible to understand which drying parameters are more efficient, in the actual energy paradigm.



# Conteúdo

<b>I</b>	<b>Enquadramento</b>	<b>1</b>
<b>1</b>	<b>Introdução</b>	<b>3</b>
1.1	O papel <i>tissue</i> e a problemática da secagem . . . . .	3
1.2	Objetivo da Dissertação . . . . .	5
1.3	Modelação de processos de secagem em ambiente industrial . . . . .	5
1.4	Revisão Bibliográfica . . . . .	5
1.4.1	O processo de secagem de papel <i>tissue</i> . . . . .	5
1.4.2	Modelos de Secagem . . . . .	6
1.4.3	Modelos de Secagem de Papel . . . . .	8
1.5	Contribuição do Estudo . . . . .	10
1.6	Organização da Dissertação . . . . .	11
<b>II</b>	<b>Modelos em Redes Neurais</b>	<b>13</b>
<b>2</b>	<b>Criação de Modelos através de Redes Neurais</b>	<b>15</b>
2.1	Introdução . . . . .	15
2.2	Fundamentos teóricos . . . . .	15
2.3	Obtenção da base de dados . . . . .	16
2.4	Rede Neuronal . . . . .	17
2.4.1	Arquitetura . . . . .	17
2.4.2	Algoritmos de treino . . . . .	18
2.5	Programação da Rede Neuronal . . . . .	19
2.5.1	Como definir a Arquitetura da RN? . . . . .	19
2.5.2	Como definir o Algoritmo de Treino? . . . . .	20
2.5.3	Como tratar a Base de Dados? . . . . .	21
2.5.4	Como utilizar a RN? . . . . .	21
2.6	Síntese e Conclusões do capítulo . . . . .	22
<b>3</b>	<b>Simulação de Processos de Secagem de Papel <i>Tissue</i></b>	<b>23</b>
3.1	Introdução . . . . .	23
3.2	Metodologia para obtenção da Base de Dados . . . . .	24
3.3	Criação do Modelo de Secagem . . . . .	28
3.4	Redes neuronais em processos mutáveis . . . . .	30
3.5	Criação do Modelo de Consumos . . . . .	30
3.5.1	Consumo do Cilindro Yankee . . . . .	31
3.5.2	Consumo Térmico da Campânula . . . . .	31

3.5.3	Consumo Mecânico da Campânula . . . . .	31
3.6	Implementação . . . . .	32
3.6.1	Ferramenta GUI . . . . .	33
3.7	Síntese e Conclusões do capítulo . . . . .	39
<b>III</b>	<b>Resultados, Discussão e Conclusão</b>	<b>41</b>
<b>4</b>	<b>Resultados</b>	<b>43</b>
4.1	Introdução . . . . .	43
4.2	Análise da Arquitetura da Rede Neuronal . . . . .	43
4.2.1	Algoritmo de Treino Levenberg & Marquardt . . . . .	43
4.2.2	Algoritmo de Treino Bayesian Regulation . . . . .	45
4.2.3	Análise da Capacidade de Generalizar . . . . .	48
4.3	Estudo do comportamento do Modelo de Secagem . . . . .	49
4.3.1	Estudo do efeito do Método 3.2 . . . . .	52
4.4	Análise do modelo de consumos . . . . .	55
4.4.1	Consumo do Cilindro Yankee . . . . .	55
4.4.2	Consumo Térmico da Campânula . . . . .	55
4.4.3	Consumo Elétrico da Campânula . . . . .	57
4.5	Análise de valores de produção através da GUI . . . . .	58
4.5.1	Teste Papel Reciclado . . . . .	59
4.5.2	Teste 4 ton/h . . . . .	60
4.5.3	Casos Extremos . . . . .	61
<b>5</b>	<b>Conclusão e Trabalhos Futuros</b>	<b>67</b>
5.1	Conclusões e Sugestões para Trabalhos Futuros . . . . .	67
<b>IV</b>	<b>Apêndices</b>	<b>73</b>
<b>A</b>	<b>Recolha de amostras de <math>H_{Yankee}</math></b>	<b>75</b>
<b>B</b>	<b>Simulações de comportamento do Modelo de Secagem para diferentes valores de Produção</b>	<b>77</b>
B.1	Produção de 4 ton/h . . . . .	77
B.2	Produção de 4.6 ton/h . . . . .	79
<b>C</b>	<b>Base de dados relativa ao teste com papel reciclado</b>	<b>81</b>



# Lista de Tabelas

2.1	Funções de transferência presentes no MATLAB® . . . . .	20
2.2	Algoritmos de Treino presentes no MATLAB® . . . . .	20
3.1	Variáveis identificadas para base de dados . . . . .	25
3.2	Testes a realizar à Rede Neuronal . . . . .	29
3.3	Variáveis escolhidas para regressão das funções de custos . . . . .	30
4.1	RMSE e MAPE para Algoritmo de <b>Levenberg &amp; Marquardt</b> com as possíveis combinações de arquiteturas . . . . .	44
4.2	RMSE e MAPE para Algoritmo de <b>Bayesian Regulation</b> com as pos- síveis combinações de arquiteturas . . . . .	46
4.3	Teste de <i>secciccate</i> à prensa . . . . .	52
4.4	Condições típicas de secagem para produção de papel reciclado . . . . .	59
4.5	Condições típicas de produção de papel reciclado . . . . .	59
4.6	Condições típicas de secagem para produção de 4 ton/h . . . . .	61
A.1	Teste de <i>seccitate</i> da Prensa . . . . .	76
C.1	Teste com papel reciclado . . . . .	81
C.2	Condições de secagem no <b>CASE 2</b> . . . . .	82



# Lista de Figuras

1.1	Consumo anual de papel tissue per capita por região do Globo. Fonte: European Tissue Symposium . . . . .	4
1.2	Representação de um sistema convencional de secagem de papel <i>tissue</i> . Fonte:(1) . . . . .	6
1.3	Representação da evolução da Taxa de Secagem ao longo do processo de secagem. Fonte:(2) . . . . .	7
2.1	Representação da Arquitetura de uma Rede Neuronal. (3) . . . . .	17
2.2	Esquematização da retro-propagação. (4) . . . . .	18
3.1	Máquina de Papel fornecida pela empresa Toscotec . . . . .	23
3.2	Fluxograma de implementação do <i>Drying Efficiency Simulator</i> . . . . .	33
3.3	Página de apresentação da aplicação . . . . .	33
3.4	Página para criação do modelo através de Redes Neurais . . . . .	34
3.5	Página para criação do modelo através de Redes Neurais após configuração . . . . .	35
3.6	Página para introdução das curvas de consumo e preços da energia . . . . .	36
3.7	Página para introdução das curvas de consumo e preços da energia após configuração . . . . .	36
3.8	Página para simulação do modelo de custos de secagem . . . . .	37
3.9	Página para simulação do modelo de custos de secagem em situação de poupança . . . . .	38
3.10	Página para simulação do modelo de custos de secagem em situação de contrapoupança . . . . .	38
4.1	Gráfico da evolução do RMSE para as duas funções de transferência . . . . .	44
4.2	Gráfico da evolução do MAPE para as duas funções de transferência . . . . .	45
4.3	Teste de Arquitetura com o Algoritmo de Treino Bayesian Regulation . . . . .	47
4.4	Gráfico comparativo da evolução do MAPE para as duas funções de transferência escolhidas . . . . .	47
4.5	Gráfico referente ao $\delta$ em função da produção . . . . .	48
4.6	Gráfico referente ao $\delta$ em função da produção . . . . .	49
4.7	Comportamento do Modelo de Secagem variando a pressão do cilindro <i>Yankee</i> . . . . .	50
4.8	Comportamento do Modelo de Secagem variando a temperatura da Câmpula . . . . .	51
4.9	Comportamento do Modelo de Secagem variando as RPM dos Recirculadores . . . . .	51

4.10	Evolução do $H_{in}$ obtido através do método 3.2 ao longo da produção . . .	53
4.11	Comportamento do Modelo de Secagem variando a pressão do cilindro <i>Yankee</i> com $H_{in}$ fixo . . . . .	53
4.12	Comportamento do Modelo de Secagem variando a temperatura da Cam- pânula com $H_{in}$ fixo . . . . .	54
4.13	Comportamento do Modelo de Secagem variando as RPM dos Recircula- dores com $H_{in}$ fixo . . . . .	55
4.14	Regressão do consumo de gás natural em função da pressão do cilindro <i>Yankee</i> . . . . .	56
4.15	Regressão do consumo de gás natural em função da temperatura dos quei- madores da Campânula . . . . .	56
4.16	Regressão do consumo de Energia Elétrica em função das <i>rpm</i> escolhidas .	57
4.17	Simulação da Proposta de poupança energética para produção de papel reciclado . . . . .	60
4.18	Histograma da Produção na base de dados . . . . .	61
4.19	Simulação da Proposta de poupança energética para produção de 4 ton/h	62
4.20	Simulação da proposta de condições extremas de funcionamento da seca- gem, desligando o queimador da Campânula . . . . .	62
4.21	Simulação da proposta de condições extremas de funcionamento da seca- gem, mantendo o cilindro <i>Yankee</i> em <i>stand-by</i> . . . . .	63
4.22	Simulação da proposta de condições extremas de funcionamento da seca- gem, maximizando valores de pressão no cilindro <i>Yankee</i> . . . . .	63
4.23	Simulação da proposta de condições extremas de funcionamento da seca- gem, maximizando valores de temperatura da Campânula . . . . .	64
A.1	Representação da zona de amostragem . . . . .	75
B.1	Comportamento do Modelo de Secagem variando a pressão do cilindro <i>Yankee</i> a 4 ton/h de produção . . . . .	77
B.2	Comportamento do Modelo de Secagem variando a temperatura da Cam- pânula a 4 ton/h de produção . . . . .	78
B.3	Comportamento do Modelo de Secagem variando a velocidade dos Recir- culadores a 4 ton/h produção . . . . .	78
B.4	Comportamento do Modelo de Secagem variando a pressão do cilindro <i>Yankee</i> a 4.6 ton/h de produção . . . . .	79
B.5	Comportamento do Modelo de Secagem variando a temperatura da Cam- pânula a 4.6 ton/h de produção . . . . .	80
B.6	Comportamento do Modelo de Secagem variando a velocidade dos Recir- culadores a 4.6 ton/h produção . . . . .	80

Parte I

**Enquadramento**



# Capítulo 1

## Introdução

Neste capítulo será introduzido o tema do papel *tissue* e da problemática da secagem. Falar-se-ão das técnicas mais disseminadas para processos de secagem de papel em geral e do papel *tissue* em particular. Vários modelos de secagem serão abordados, bem como a metodologia usada no seu desenvolvimento.

### 1.1 O papel *tissue* e a problemática da secagem

O papel é utilizado numa infinidade de aplicações, desde livros, cadernos, caixas, embrulhos, até papel para higiene pessoal. Devido a esta infinita panóplia de utilizações, seria difícil imaginar a nossa vida sem esta invenção milenar.

Devido à disseminação extrema deste produto, a sua presença tornou-se imprescindível. Contudo, as enormes pressões comerciais levam a que apenas seja vantajosa a sua produção em larga escala de modo a obter os melhores lucros com a menor margem possível.<sup>(5)</sup> Uma máquina de papel numa fábrica comporta um custo muito avultado. Portanto, quanto maior for a produção, mais rápida é a amortização, caso contrário o investimento é inviável.

As pressões para utilizar cada vez menos papel de escrita têm aumentado, levando a que este tipo de papel seja substituído por meios eletrónicos equivalentes. Contudo, o consumo de papel *tissue* não é suscetível a reduções, não tendo sido encontrado um substituto interessante. O consumo deste tipo de papel é cada vez mais disseminado devido ao forte crescimento das economias emergentes.

É possível observar no gráfico que se segue 1.1, referente ao ano de 2009, o consumo per capita de papel *tissue* por regiões do globo, indicando o potencial de expansão deste produto para estas economias.




Figura 1.1: Consumo anual de papel tissue per capita por região do Globo. Fonte: European Tissue Symposium

Um crescente aumento da procura de produtos de papel *tissue* nas últimas décadas levou a que o consumo de energia associado à secagem aumentasse consideravelmente (6), tornando-se necessária a otimização deste processo de modo a diminuir custos financeiros e ambientais sem comprometer a qualidade do produto final.

Tendo em conta que uma das variáveis de controlo de qualidade é a humidade do papel, variável esta que também é responsável pelo comportamento físico de muitas outras, é necessário que esta seja bem controlada e comportando o menor custo possível.

O interesse pela otimização da secagem deve-se a várias razões, tais como (7):

- Grandes variações na humidade do papel podem prejudicar tarefas de pós-processamento, como o *converting*. Estas variações poderão levar a que o papel não passe no controlo de qualidade e que tenha de ser rejeitado;
- Um bom controlo da variação de humidade poderá levar a um aumento do valor médio de humidade. Processo que será vantajoso para as empresas produtoras de papel, pois poderão vender água ao preço do papel e ainda poupar custos energéticos associados à secagem;
- Como referido anteriormente, um dos pressupostos para rapidamente obter a amortização do investimento e maximizar os lucros é o aumento da produção. A máxima produção só é possível a uma velocidade máxima, contudo, na maioria das vezes o processo de secagem é o *bottle-neck* do processo global e portanto, um controlo mais ativo da humidade poderá levar a que seja possível trabalhar mais próximo do ponto crítico;
- Propriedades como a rigidez, dureza, resistência e o alongamento estão dependentes da humidade [Gavelin, 1972].



## 1.2 Objetivo da Dissertação

O objetivo da dissertação consiste em desenvolver uma caracterização dinâmica do consumo energético no processo de secagem de papel, diferenciando o contributo de cada técnica interveniente para a secagem. Um modelo matemático que permita descrever de forma adequada o processo de secagem de papel *tissue* em ambiente industrial será desenvolvido e validado.

Para além do desenvolvimento de um modelo para um caso de estudo específico, o cerne desta dissertação é o desenvolvimento de um método geral e transversal para criação de modelos de secagem através de Redes Neurais.

Com o modelo criado através do uso de Redes Neurais, pretende-se compreender o peso de cada uma das variáveis em jogo no custo energético final, de modo a facilitar as tomadas de decisão na escolha dos parâmetros de secagem, promovendo a poupança energética e ambiental.

## 1.3 Modelação de processos de secagem em ambiente industrial

A criação de um modelo representativo do processo de secagem é uma solução economicamente interessante, visto que permitirá a poupança de custos de processo sem alterar a construção da máquina, garantindo a qualidade desejada do papel (8).

O consumo de combustíveis fósseis e de energia elétrica é dos aspetos mais relevantes do ponto de vista da produção de papel. O consumo energético da indústria papeleira, em termos globais, ocupa o 3º lugar das indústrias consumidoras de energia e lidera o *ranking* no que toca à energia consumida em operações de secagem (9) (10). Um terço é a fração relativa ao processo de secagem, não só no investimento total de uma máquina de papel, mas também no custo total de produção.

Sendo assim, do ponto de vista industrial, esta oportunidade de poupança é interessante, até porque, com um modelo da secagem bem definido, é possível retirar partido, por exemplo, da estrutura tarifária dos tipos de energia envolvidos, (gás natural e eletricidade).

Em ambientes industriais, a possibilidade de criação de um modelo é dificultada e limitada se se comparar com modelos obtidos experimentalmente em laboratório. Os graus de liberdade são menores e o controlo de vários parâmetros é dificultado. No entanto, a aplicabilidade é extrema e o interesse ainda mais elevado. Devido à complexidade dos sistemas, não é frequente encontrar na literatura, desenvolvimento de modelos em ambientes industriais.

## 1.4 Revisão Bibliográfica

### 1.4.1 O processo de secagem de papel *tissue*

Na maioria das máquinas de papel *tissue*, o processo de secagem está a cargo de dois equipamentos principais consumidores, quer de Gás Natural, quer de Energia Elétrica: o cilindro Yankee e a Campânula.

Na figura 1.2 é possível observar a representação de um desses sistemas, onde *Yankee Cylinder* representa o cilindro Yankee e onde *Wet Hood* e *Dry Hood* representam a

Campânula da parte Húmida e da parte Seca, respetivamente. Não fazendo parte do estudo, mas não menos importante para a secagem está representada a Prensa de Vácuo, *Vacuum press*, cuja função é retirar água da folha de papel por ação de vácuo.




Figura 1.2: Representação de um sistema convencional de secagem de papel *tissue*.  
Fonte:(1)

O cilindro Yankee consiste num cilindro em aço inoxidável aquecido por vapor saturado a uma pressão definida pelo operador de máquina. Este condensa no seu interior libertando energia que é fornecida ao papel por condução através da parede do cilindro, promovendo a sua secagem.

A Campânula consiste num sistema de secagem por convecção forçada de ar quente aquecido por queimadores de gás natural, o qual é injetado sobre o papel a secar por efeito de ventiladores dedicados. Deste modo promove-se a troca de calor e de massa, sem contacto ou efeito mecânico sobre o produto. Esta técnica é designada na literatura por *impingement jets*.

#### 1.4.2 Modelos de Secagem

De modo a melhor compreender os fenómenos físicos por detrás do processo de secagem foram analisados vários modelos representativos de problemas desta natureza.

Em (2) Mujumdar, faz uma revisão aos princípios dos fenómenos físicos da secagem. Neste livro são descritas várias leis de transferência de massa e de calor, bem como modelos de difusão de Fick.

Abordou-se a problemática da não linearidade inerente à Taxa de Secagem (TS). Esta reflete a variação do teor de humidade da amostra em causa, ao longo do tempo.

Na figura 1.3, está representada a evolução da TS ao longo do processo. Após uma fase de ativação, ocorre a fase constante da taxa de secagem. Esta apenas depende do somatório dos mecanismos de transferência de calor nos quais os fluxos de calor dependem da superfície exposta. Esta fase depende também da entalpia de vaporização

referente à pressão em estudo, visto que, nesta fase é considerado que a superfície de transferência se encontra com um filme de água livre para evaporação.




Figura 1.3: Representação da evolução da Taxa de Secagem ao longo do processo de secagem. Fonte:(2)

Esta relação pode ser observada através da equação 1.1, onde  $q$  representa todos os meios de transferência, seja por convecção, condução, radiação ou todos em simultâneo.  $\lambda_s$  representa a entalpia de vaporização da água.

$$N = \frac{\sum q}{\lambda_s} \quad (1.1)$$

Em teoria, a TS será constante até que a humidade atinja o ponto crítico  $X_c$ . Após este ponto, a taxa de secagem deixa de poder ser representada através da equação 1.1, devido a limitações no transporte interno de água impossibilitam manter água livre na superfície de transferência. Por consequência, o material não consegue ser seco a uma TS equivalente à anterior, começando a decair à medida que a humidade vai diminuindo. Tratando-se de um fenómeno de transporte de água, o cálculo da TS desta fase está dependente, quer das condições de secagem, quer das características físicas do material em causa.

Uma forma de obter a TS nesta fase será realizar testes experimentais de modo a obter a curva de secagem onde a humidade é lida ao longo do tempo. Desta curva é possível retirar a TS resolvendo a equação 1.2.

$$t_d = - \int_{X_1}^{X_2} \frac{M_s}{A} \frac{dX}{N} \quad (1.2)$$

No entanto, cada curva da taxa de secagem representa apenas um conjunto de condições de secagem e do material em estudo.

Através da Lei de Fick e resolvendo a equação diferencial 1.3 é possível obter o tempo de secagem e consequentemente a TS.

$$\frac{\delta X_f}{\delta t} = D_L \frac{\delta^2 X_f}{\delta x^2} \quad (1.3)$$

Onde as condições iniciais são as seguintes:

- $X_f = X_i$ , em toda a amostra no instante inicial;
- $X_f = 0$ , quando  $x = a$  ou seja a humidade na superfície de transferência é zero;
- $\frac{\delta X_f}{\delta t} = 0$ , e toda a superfície.

Neste modelo é assumido que a difusão ocorre unidireccionalmente, onde a difusividade é constante  $D_L$ . O valor de difusividade encontra-se tabelado na literatura, contudo, do ponto de vista prático pode incorrer-se em erros visto não ser uma característica única e exclusiva do material. Esta depende também das condições de secagem e da geometria em causa.

(11) Neste artigo foi investigado o efeito de impinging slot-jets no numero transferência de massa de High Schmidt. Neste caso são considerados números de Reynolds na gama entre 13000 e 14000. É estudada a relação entre o número de High Schmidt e o número de Reybolds.

São definidas as relações entre o número de Nusselt e a largura do jato, com a demonstração da propagação do número de Nusselt ao longo da zona de transferência de massa.

(12) Neste artigo, é desenvolvido um modelo e redes neuronais para secagem de tomate. Neste caso, é comparada a velocidade do ar e a potência dos aquecedores, verificando-se que o modelo em redes neuronais confere melhores resultados que aqueles obtidos através de modelos analíticos para a secagem.

Para a melhor correlação empírica foi possível obter um erro de 5.32 % através da correlação matemática de Page. Com os mesmos dados e através da rede neuronal foi possível obter um valor de 1.18 %.

(4) Tal como no caso anterior, este também utiliza redes neuronais para modelar o processo de secagem de produtos alimentares.

São realizados testes em diferentes condições de secagem alimentando uma rede neuronal onde as variáveis de processo são a temperatura e atividade da agua e as de secagem são a temperatura da amostra, a humidade relativa do meio e a temperatura de secagem.

As variáveis, após simuladas, realimentam o sistema de modo a obter uma curva de secagem ao longo do tempo até ao valor de equilíbrio do teor de humidade. As diferentes arquiteturas da Rede Neuronal são testadas e é escolhida a função de transferência de Sigmoidal e 9 neurónios na camada oculta, sendo a que apresenta melhor valor de MSE (*Mean Squared Error*) e  $R^2$ .

### 1.4.3 Modelos de Secagem de Papel

(13) Tese de doutoramento, onde Jean simula as condições de secagem de um possível secador industrial através de jatos de vapor sobreaquecido (*superheated steam impingement jets*). É observada a curva de queda da taxa de secagem. São testadas diferentes

condições de secagem de modo a obter relações entre o número de Reynolds e a temperatura do jato.

Várias experiências demonstram uma correlação interessante entre os fatores influenciadores da taxa de secagem, como representado na equação 1.4

$$R_{CS} = \{R_1(k, C_{ps}, Pr, \Delta T, \Delta H_v)\} \left\{ \frac{F(H/D, f)}{D} Re_j^{2/3} \right\} \quad (1.4)$$

Nesta correlação são separados os efeitos da temperatura, à esquerda, dos efeitos da geometria, à direita.

É também proposto um sistema de secagem através de vapor sobreaquecido. Este é introduzido no início do processo de modo a fomentar a secagem onde a TS ainda é constante.

A tese inside em larga escala na secagem de papel normal, no entanto, foram realizados alguns testes com papel *tissue*.

Em 2004, Weineisen (14) analisa a técnica de secagem por TAD (*Through Air Drying*), onde ar aquecido é projetado através da folha de papel.

Foi desenvolvido um modelo tendo em conta as equações de continuidade usando as correlações entre os coeficientes transferência de massa e de calor, nas quais se verifica a proporcionalidade direta entre ambos.

Várias geometrias foram experimentadas de modo a tentar obter um modelo o mais geral possível. Quando a experiência envolve baixas taxas de transferência de massa e de calor, o modelo desenvolvido corresponde às previsões dos modelos encontrados na literatura. Para taxas elevadas este modelo revela previsões mais elevadas que o espectável, apresentando um desvio considerável dos valores experimentados.

Em (15) foi melhorado um modelo de secagem de papel convencional já aplicado a industria. Foi mantida a simplicidade necessária a uma aplicação industrial, contudo a performance do modelo foi melhorada.

Com simples pressupostos obtinha-se uma resposta relevante, mas com a melhoria do modelo a resposta em relação ao medido experimentalmente foi melhorada. Para além de melhor resposta, também o custo computacional foi melhorado pelo aumento da simplicidade no método de computação.

O modelo foi desenvolvido de modo a obter uma curva da humidade na dimensão transversal à direção da produção da folha de papel.

(7) Tese de doutoramento acerca do controlo de uma maquina de papel. Numa maquina de papel convencional é criado um modelo de controlo da humidade do papel através do controlo da pressão de vapor definida para a bateria de cilindros.

Neste trabalho é referido o método de obtenção do teor de humidade por gravimetria, em ambiente industrial, representado pela equação 1.5.

$$w = \frac{100m_{wc}}{m_{wc} + m_{ds}} \quad (1.5)$$

Onde  $w$  representa o Teor de Humidade.  $m_{wc}$  representa a massa de água presente na amostra e  $m_{ds}$  a massa de pasta seca.

Apesar de interessante, do ponto de vista de teorias de controlo, o foco da tese está no problema específico de modelar o processo de secagem de uma máquina de papel.

Em 2007 (16) é apresentada a evolução do modelo anterior (14). Neste caso, entra-se mais em detalhe e são consideradas mais propriedades físicas do papel e do meio de transferência. Foram testadas diferentes composições de papel e de condições de secagem de acordo com o existente a nível industrial.

As conclusões explicam que o mais importante na criação deste modelo é afinar as simulações de modo a que a correlação entre caudal de ar e queda de pressão seja a mais adequada, pois a taxa de secagem é bastante influenciada por estes fatores.

Por outro lado, os testes realizados, comparando variações de temperatura, de gramagem e de queda de pressão, não apresentam resultados concordantes o que prova que a relação entre queda de pressão e caudal não é capaz de demonstrar a não linearidade do processo de secagem.

Em (17) um modelo complexo foi criado, com a obtenção exaustiva de vários parâmetros de secagem ao longo do processo de secagem. O modelo analisa o processo de secagem microscopicamente, tendo em conta, não só os fenómenos de transferência de calor e de massa presentes na secagem, mas também tem em conta a difusão da água em meios porosos, como é caso do papel.

(18) Este artigo refere a influência de diferentes condições de secagem nas propriedades físicas do papel. São realizados testes variando temperaturas e velocidades do ar e são calculadas as respetivas taxas de secagem.

Foram também analisadas as características físicas do papel após secagem e verificou-se que a altas temperaturas de secagem, a sua qualidade é prejudicada.

## 1.5 Contribuição do Estudo

O desenvolvimento de modelos de secagem, para além de envolver problemas de transferência de calor e de massa, envolve também problemas no âmbito dos materiais. Isto é, mesmo usando o mais simples dos modelos anteriormente descritos baseado na lei de Fick, seria de extrema dificuldade obter os dados dos quais os coeficientes de massa e de calor são dependentes. Considerem-se a velocidade de jato na zona de transferência, a temperatura e teores de humidade do meio de transferência e do papel, para além de vários fatores como a complexidade do sistema, não-linearidades do processo ou a inexistência de dados de boa qualidade para a modelação.

É necessário um estudo exaustivo de laboratório e com modelos à escala de modo a que se obtenham os pressupostos necessários para a criação do modelo de secagem.

Uma análise laboratorial deste género é de custos elevadíssimos, quer de equipamentos, modelos à escala e outros recursos materiais, quer de recursos humanos e de tempo.

Portanto, criar um modelo de secagem de papel através da análise física do processo implicaria um custo elevadíssimo do ponto de vista prático. É pertinente que seja abordado este tema envolvendo redes neuronais devido ao facto de não ser viável acarretar os custos necessários para um modelo físico e também devido à literatura acerca de papel *tissue* ser limitada.

Tendo isto em conta, pretende-se explorar a capacidade das Redes Neuronais em

desenvolver um modelo capaz de descrever o processo de secagem em ambiente industrial, com o menor impacto na produção e deste modo contribuir para o desenvolvimento de conhecimento científico no âmbito da secagem de papel e em particular do papel *tissue*.

Para tal, deverá organizar-se uma base de dados através da obtenção de valores em ambiente industrial sendo depois utilizadas redes neuronais para a criação do modelo de secagem de papel *tissue*.

## 1.6 Organização da Dissertação

A presente dissertação está dividida em 3 partes e 5 capítulos.

No Capítulo 1, é exposta uma revisão bibliográfica onde são abordados o tema do papel *tissue*, são analisados modelos de secagem em geral e de secagem de papel em particular. São também abordados, modelos realizados através de Redes Neuronais e a contribuição desta dissertação.

No Capítulo 2 o tema das redes neuronais é abordado de forma cuidada e é delineado um método geral de criação de modelos de secagem, através da utilização de Redes Neuronais.

O Capítulo 3 é a aplicação e implementação do Capítulo 2. Aqui é desenvolvido um modelo de secagem específico para uma máquina de papel *tissue* usando redes neuronais, usando os princípios relatados no capítulo anterior. É desenvolvida e explicada uma ferramenta informática cuja finalidade é utilizar o modelo de secagem de forma interessante.

No Capítulo 4 são expostos e discutidos os resultados obtidos da implementação do modelo de secagem. São simuladas condições de poupança energética simuladas através da aplicação em MATLAB<sup>®</sup> desenvolvida.

O Capítulo 5 apresenta e discute as principais conclusões globais decorrentes do trabalho. São ainda discutidas algumas sugestões para trabalho futuro.





## Parte II

# Modelos em Redes Neurais



## Capítulo 2

# Criação de Modelos através de Redes Neurais

### 2.1 Introdução

A criação de modelos representativos de processos com elevada complexidade leva a que seja necessário um recurso de tempo proporcionalmente elevado. Em ambientes industriais, a complexidade dos sistemas aumenta devido à dificuldade de medição de determinados aspetos produtivos. Numa grande parte dos casos, o controlo de operações é realizado por parte do operador. Este desenvolveu uma rede neuronal na qual armazena as características do sistema bem como o modelo que o representa. O estudo de ferramentas de *Soft Computing*, tendo como base o funcionamento do cérebro tornou mais acessível a criação de modelos complexos através da aprendizagem de uma Rede Neuronal (19). Tendo isto em conta, é aliciante a criação de modelos de forma mais simplificada e com menor distúrbio na produção.

Neste capítulo será apresentada a criação de modelos através de RN, demonstrando fraquezas e pontos fortes de tal abordagem.

### 2.2 Fundamentos teóricos

As RN são modelos heurísticos, como tal, todo o seu comportamento pode ser comparado à vasta rede de neurónios presente no cérebro dos humanos. Estas são construídas através da criação de relações simples entre diversos elementos computacionais, chamados de neurónios. Tal como no ser humano, as redes neuronais criam relações entre o conhecimento adquirido e novas realidades. Elas têm capacidade de aprendizagem. (4) As redes neuronais criam funções matemáticas capazes de descrever processos, sistemas, imagens, sons e todo o campo do conhecimento passível de criação de padrões. O conhecimento adquirido pode ser comparado a uma base de dados onde estão presentes pares de inputs com os outputs respetivos. É possível treinar um conjunto de neurónios para a criação de relações de causalidade entre inputs e outputs. Treinar significa aplicar a cada conexão entre neurónios um determinado peso que amplificará positiva ou negativamente a informação que seja transmitida por estes. Desta forma, a rede neuronal poderá relacionar conhecimento adquirido com novas realidades e prever o output expectável.

A expressão 2.1 representa como a rede neuronal poderá calcular novos *targets*.

$$target = \eta(input, weights) \quad (2.1)$$

Onde  $\eta$  representa a arquitetura da rede neuronal,  $input$  é o conjunto de novos valores a simular e  $weights$  são os pesos associados à arquitetura.

As RN podem ser classificadas em dois grandes grupos, as supervisionadas e as não-supervisionadas. As RN supervisionadas são aquelas que necessitam de um algoritmo de treino que condicione o método de aprendizagem; as não-supervisionadas têm a liberdade de adaptar, por elas mesmas, os pesos associados às conexões, de modo a obter os outputs pretendidos. Para o caso de necessidade de modelação de um processo de secagem como é o caso desta dissertação, as RN supervisionadas são as mais indicadas (20).

Em problemas de engenharia, um tipo de rede largamente utilizado são as Redes Neurais Multilayer Feedforward (MFNN).

As MFNN organizam os neurónios por camadas ocultas que são alimentadas diretamente pela camada de entrada sem realizar qualquer computação dos valores em causa. Após computação dos valores, por parte da camada oculta, usando funções de transferência conhecidas pela teoria de controlo, a camada de output é alimentada, expondo assim os valores previstos pela RN.

### 2.3 Obtenção da base de dados

Para que uma rede neuronal tenha uma representatividade aceitável do sistema a modelar, é fundamental que esta tenha como suporte uma boa base de dados representativa da realidade. Tal como na teoria de controlo, também aqui é necessário ter um conhecimento físico do processo, para escolher as variáveis realmente relevantes na sua caracterização.

É necessário que sejam definidos valores de parâmetros de entrada do processo que influenciem diretamente o/os resultados a observar. Assim que esses parâmetros sejam identificados é mandatório criar uma base de dados onde estes pares de valores sejam repetidos vezes suficientes a fim de representar convenientemente o processo. Todavia, a complexidade de processos a nível industrial poderá tornar quase inatingível chegar a esse número ideal de valores

A arquitetura das FFNN permite que a base de dados seja organizada por um sistema vetorial:

$$x_i = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}; y_i = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}$$

As redes neurais são problemas de estatística não linear. Como tal, é necessário que a base de dados sofra um tratamento estatístico prévio à computação.

Este tratamento prévio, conhecido por pré-processamento ou iniciação da RN, otimiza o funcionamento da RN, normalizando a base de dados. Assim, todos os valores ficam compreendidos no domínio das funções de transferência, de forma a que o desvio padrão seja igual a 1 (um) e que tenham média de zero (19).

Com esta homogeneização, a tarefa de treino torna-se mais eficiente e com menor custo computacional.

A Base de Dados necessita de ser dividida em 2 grandes grupos. Uma parte é utilizada pela rede neuronal para realizar o treino e a parte restante é utilizada para efeitos de validação e teste à RN criada.

## 2.4 Rede Neuronal

### 2.4.1 Arquitetura

A arquitetura das redes neuronais consiste em organizar as ligações entre neurónios e os pesos que lhes estão associados. Nos modelos de redes neuronais FFNN, os neurónios encontram-se agrupados em camadas escondidas. Em problemas de engenharia e na criação de modelos associados à secagem é comum que o número de camadas escondidas seja de apenas uma. Desta forma, a simplicidade da RN é facilitada sem comprometer a sua eficiência.

Ao contrário do que acontece nas redes neuronais presentes no cérebro, nas FFNN, os dados são computados simultaneamente e como o próprio nome indica, ligam-se unidirecionalmente às camadas consequentes até à camada dos resultados. Uma representação de FFNN, que é largamente utilizada na literatura, é feita sob a forma de árvore, como se pode observar na figura.

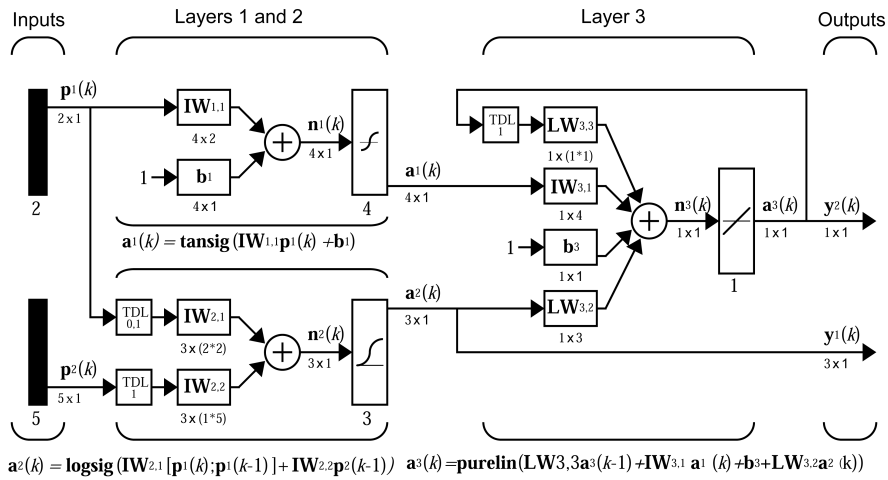


Figura 2.1: Representação da Arquitetura de uma Rede Neuronal. (3)

Esta representação contempla todos os intervenientes computacionais presentes numa RN. É possível observar que a camada de parâmetros de entrada alimenta diretamente, sem sofrer qualquer tipo de computação, a primeira camada oculta de neurónios. Nesses neurónios os pesos e as *biases* que lhes estão associados, são obtidos através do treino da RN por retro-propagação tendo em conta a função de transferência escolhida para a dada camada.

Cada camada oculta tem associada uma função de transferência. Apesar de uma grande variedade de funções de transferência disponíveis, na camada oculta de uma FFNN, o interesse no desenvolvimento de modelos, recai em duas funções. A tangente hiperbólica sigmoidal e o logaritmo sigmoidal. O teste com ambas é imperioso de modo a definir o modelo em causa.

É considerado de boa norma, em problemas de previsão, a utilização da função de transferência pure-lin na ultima camada.

A retro-propagação revolucionou o modo de treino das RN. Neste método, após uma simples computação sem pesos associados, o resultado na camada final é comparado com o resultado presente na base de dados. Este será retropropagado até camada dos parâmetros de entrada onde os dados computados serão novamente comparados. Esta comparação permite o cálculo do desvio  $\delta$  (19), parametro muito importante para o cálculo dos pesos.




Figura 2.2: Esquematisação da retro-propagação. (4)

#### 2.4.2 Algoritmos de treino

O objetivo do treino da RN é fazer com que o desvio entre o output calculado e o correspondente na base de dados seja o menor possível.(19) Para tal, é realizado treino com retro-propagação de forma a escolher os pesos mais adequados para cada um dos neurónios. Contudo, é necessário compreender que a realização desta tarefa necessita de uma enorme capacidade de computação que será tanto maior quanto maior for a dimensão da base de dados e da quantidade de neurónios presentes na camada oculta.

A escolha do algoritmo perfeito para que o erro se aproxime praticamente de zero está inerente a problemas de computação. Por vezes, seria interessante a utilização do método de Newton. Contudo, os recursos computacionais necessários para o cálculo da matriz Hessiana e RN com retro-propagação seriam esmagadores, mesmo em RN de extrema simplicidade. Tornou-se então necessário desenvolver algoritmos mais acessíveis do ponto de vista computacional.

Para efeitos de previsão, como é o caso desta tese, o algoritmo mais em voga para treino de redes neuronais é o de Levenberg-Marquardt (LM)(21). Este método é deveras atrativo pois evita o cálculo da matriz Hessiana do erro. Este facto permite uma maior

velocidade de computação e também uma maior quantidade de memória utilizada. No entanto excelentes valores de erro associados são fáceis de ser modelados com um baixo custo computacional.

Um algoritmo muito interessante na literatura e presente no MATLAB® é o Bayesian Regulation, também por retropropagação e baseado no LM. No entanto, ao invés do LM, onde o parâmetro de performance é observado no RMSE, com algoritmo BR, tanto o RMSE como a média da soma quadrática das biases e dos weights (MSW) são estudados. Pela minimização de ambos, RMSE e MSW, este algoritmo melhora a capacidade de generalização do modelo da rede neuronal pelo desenvolvimento de redes com menores pesos e biases que leva a uma resposta mais suave. (3)

## 2.5 Programação da Rede Neuronal

Tendo em conta que as FFNN são aproximáveis a funções matemáticas, a sua programação pode ter lugar nas mais diversas plataformas. Contudo, o MATLAB® contempla uma *toolbox* dedicada às RN que se encontra bem documentada e o seu uso em problemas de engenharia está altamente disseminado. Neste problema de criação do modelo referente à secagem, recorreu-se a este *software* e a sua implementação será documentada de seguida.

Definição do problema:

- Como tratar a Base de Dados?
- Como definir a Arquitetura da RN?
- Como definir o Algoritmo de Treino?
- Como utilizar a RN?

### 2.5.1 Como definir a Arquitetura da RN?

Para criar uma RN com o carácter de FeedForward no MATLAB® recorre-se aos comandos definidos pela *Neural Network Toolbox*.

```
RN=newff(input,target,[nN1 nN2],{'transfer function'},'train algorithm'); % ←  
criação da arquitetura da RN
```

A função que define uma RN FeedForward, como se pode constatar, é *newff* onde todas as características necessárias à criação de uma RN têm de ser contempladas. A base de dados necessita ser organizada em duas matrizes (input e target) de dimensões equivalentes. Estas correspondem aos dois primeiros parâmetros da função *newff*.

De seguida, é necessário definir o número de camadas ocultas e a quantidade de neurónios nelas incorporados. Neste caso, o vetor  $[nN1\ nN2]$  define que existem 2 camadas ocultas que contêm  $nN1$  e  $nN2$  neurónios, respetivamente. Sabe-se que para problemas com necessidade de previsão, o valor comum para o número de camadas ocultas é de apenas uma, não obstante o número ideal de neurónios depender de caso para caso. E para obter um número adequado é necessário que a RN seja treinada com diferentes valores, de forma a procurar o resultado mais satisfatório.

Tabela 2.1: Funções de transferência presentes no MATLAB®

Código	Função de Transferência
compet	Competitive transfer function
hardlim	Hard-limit transfer function
hardlims	Symmetric hard-limit transfer function
logsig	Log-sigmoid transfer function
netinv	Inverse transfer function
poslin	Positive linear transfer function
purelin	Linear transfer function
radbas	Radial basis transfer function
radbasn	Normalized radial basis transfer function
satlin	Saturating linear transfer function
satlins	Symmetric saturating linear transfer function
softmax	Softmax transfer function
tansig	Hyperbolic tangent sigmoid transfer function
tribas	Triangular basis transfer function

Cada camada oculta tem associada aos seus neurónios uma determinada função de transferência. Existem inúmeras disponíveis, tabela 2.1, mas para este tipo de problemas o interesse recai apenas na logaritmo-sigmoidal e na tangente hiperbólica-sigmoidal, as quais são definidas utilizando o código correspondente.

### 2.5.2 Como definir o Algoritmo de Treino?

O algoritmo de treino é definido tal como os parâmetros apresentados até então. Há uma vasta lista de algoritmos disponíveis na biblioteca da *toolbox*, tabela 2.2. Para um problema de previsão, basta considerar os algoritmos de Levenberg-Marquardt e de Bayesian Regularization.

Tabela 2.2: Algoritmos de Treino presentes no MATLAB®

Código	Algoritmo de Treino
Trainlm	Levenberg-Marquardt
Trainbr	Bayesian Regularization
Trainbfg	BFGS Quasi-Newton
Trainrp	Resilient Backpropagation
Trainscg	Scaled Conjugate Gradient
Traincgb	Conjugate Gradient with Powell/Beale Restarts
Traincgf	Fletcher-Powell Conjugate Gradient
Traincgp	Polak-Ribière Conjugate Gradient
Trainoss	One Step Secant
Traingdx	Variable Learning Rate Gradient Descent



Será sempre necessário analisar a performance da RN com os diferentes tipos de algoritmos para escolher acertadamente de algoritmo de treino.

Com a definição destes parâmetros, há vários que são definidos por defeito pelo MATLAB®:

- O número de neurónios da ultima camada é igual ao número de outputs em estudo;
- A função de transferência da ultima camada é purelin;

### 2.5.3 Como tratar a Base de Dados?

As chamadas funções de pré-processamento são definidas com uma linha de código consequente à criação da RN.

```
RN.inputs{1}.processFcns = {'fixunknowns','mapminmax','mapstd'};
```

Deste modo a base de dados é tratada de modo a ser melhor interpretada pela RN e assim obter resultados mais satisfatórios. Estas funções eliminam valores que sejam impossíveis de computar pela sua natureza, mapeia de forma a que todos eles estejam normalizados no domínio da função de transferência e mapeia de forma a que o desvio padrão entre eles seja de 1.

### 2.5.4 Como utilizar a RN?

Após todos os parâmetros inerentes à criação da RN estarem definidos, é necessário iniciar o treino da rede. Para efeitos de treino a seguinte linha de código precisa de ser implementada:

```
RN.performFcn = 'msereg'; \\
RN.performParam.ratio = 0.5; \\
RN.trainParam.show = 5; \\
RN.trainParam.epochs = 300; \\
RN.trainParam.goal = 1e-5; \\
RN=train(RN,input,target); \\
```

O treino será, então, realizado através de retro-propagação comparando as matrizes input e target até o erro ser mínimo sem o problema de haver over-fitting. Over-fitting ocorre quando o erro é o menor possível mas consequentemente a RN perde capacidade de generalização. Este problema pode ser impedido forçando a interrupção do treino caso algum dos parâmetros de over-fitting for verificado.

A RN está pronta a ser utilizada.

```
test_input=[x]'; %definido os novos parâmetros a ←
simular
Simulated Output=sim(RN,test_input) %Simula o novo cenário definido
```

Invocando a função *sim()* e definindo um novo set de inputs é possível simular novos outputs de acordo com a RN previamente treinada.

## 2.6 Síntese e Conclusões do capítulo

Neste capítulo foi introduzido e explicado o conceito de Redes Neurais e o seu funcionamento. Dissecou-se este conceito em dois pontos essenciais: A arquitetura; e ou Algoritmo de Treino.

Para problemas de previsão, e de modelação deste tipo de processos percebeu-se: Que uma camada oculta é suficiente; E que apenas dois tipos de funções de transferência e de Algoritmos de Treino, carecem de especial atenção nesta abordagem. *tansig* e *logsig* para as funções de transferência. E para os algoritmos de treino Levenberg-Marquardt e Bayesian Regularization.

Foi explicado o método de programação da Rede Neuronal através do MATLAB® respondendo a 4 questões:

- Como tratar a Base de Dados?
- Como definir a Arquitetura da RN?
- Como definir o Algoritmo de Treino?
- Como utilizar a RN?

Em suma, encontra-se explicitado o método de criação e utilização de uma Rede Neuronal, através do MATLAB®, para o desenvolvimento de um modelo representativo de um processo genérico.

## Capítulo 3

# Simulação de Processos de Secagem de Papel *Tissue*

### 3.1 Introdução

O objetivo deste capítulo é aplicar os conhecimentos adquiridos no capítulo [2] e aplicá-los a um caso de estudo concreto. O objeto de estudo é a parte da secagem da Máquina de Papel *tissue* (MP) figura 3.1 da empresa AMS-Gomá Camps sediada em Vila Velha de Ródão.




Figura 3.1: Máquina de Papel fornecida pela empresa Toscotec

O primeiro passo na produção de qualquer tipo de papel é a preparação de pastas, processo que se encontra a montante da MP. Nesta etapa são definidas as quantidades necessárias de fibra longa (proveniente da madeira de pinho) e fibra curta (proveniente da madeira de eucalipto) tendo em conta as especificações técnicas de cada tipo de papel. Finalizada a preparação da pasta, é realizada a junção da pasta de fibra curta, longa e quebras, nas quantidades, previamente estabelecidas, no tanque de mistura. Concluída a mistura, esta é bombeada para o tanque da máquina, à saída do qual, existe um refinador, por onde passa a pasta. Depois do processo de refinação, a pasta é enviada à Fun Pump, onde esta é diluída com água de processo (até valores com cerca de 96% de água na mistura). Segue para o crivo pressurizado, onde decorre nova depuração da pasta. Concluída esta etapa, a pasta encontra-se preparada para ser enviada para a máquina de papel.

Na máquina de papel, a pasta é projetada entre a teia e o feltro, onde grande parte

da água existente na pasta é drenada através da teia. A folha de papel já formada segue com o feltro até à prensa aspirante (2), onde devido à ação do vácuo (criado no interior da prensa), parte da água existente na folha é removida. De seguida a folha é enviada ao secador Yankee, onde é efetuada a secagem da folha, através da ação conjunta do ar quente da campânula e do calor proveniente do cilindro Yankee.

O processo de secagem na máquina de papel está a cargo de dois grandes intervenientes, o Cilindro Secador Yankee (2) e a Campânula que o envolve (3). O Yankee é responsável pela secagem do papel através de condução de calor entre as suas paredes exteriores e o papel. Neste caso, o calor é transferido entre o vapor saturado no interior do cilindro e a superfície do papel. Por outro lado, a transferência de calor através de convecção forçada e transporte de água evaporada está a cargo da Campânula que consiste em queimadores de gás natural e em ventiladores. A combinação destes dois faz com que haja uma projeção de jatos de ar a altas temperaturas sobre o papel, bem como a aspiração da água evaporada.

O controlo de qualidade referente à secagem é o teor de Humidade no papel ( $\approx 5\%$ ) à saída da rebobinadora (5) e a suavidade. Tendo em conta que o único parâmetro passível de ser mensurável é o teor de Humidade, o objeto de estudo centrou-se em tornar a secagem mais eficiente sem comprometer este parâmetro.

Neste capítulo será abordada a metodologia específica que foi utilizada na obtenção de dados, será exposta a parte relevante do código MATLAB®, será explicado o método utilizado na criação do Modelo de Custos, abordar-se-á a problemática da RN necessitar estar aberta a mutações do processo produtivo e demonstrar-se-á como implementar uma RN de forma a obter um modelo do processo de secagem.

## 3.2 Metodologia para obtenção da Base de Dados

Tendo em conta que as redes neuronais criam modelos eurísticos, para que a criação de um modelo fosse eficiente, era necessário criar uma base de dados representativa do fenómeno físico da secagem.

Pela mesma ótica, o único local para adicionar inteligência na criação do modelo é na criação da base de dados, visto que a tarefa de treino é cega e é, em boa parte, idêntica à tarefa de aprendizagem dita comum, visto que apenas aprende aquilo que lhe é ensinado.

Do processo industrial de produção foram identificadas as variáveis mais importantes e capazes de descrever o processo de secagem. Estas estão representadas na tabela 3.1.

As **Variáveis de Processo** representam a produção que ocorre a cada instante. É possível condensar estas variáveis em apenas uma, a produção. Para tal é utilizada a equação 3.6 . Sendo assim, a produção representará todas as variáveis de processo e é diretamente proporcional à quantidade de água que entra no processo de secagem.

$$prod = gm \cdot v_{MP} \cdot crepe \cdot L_{bobina} \quad (3.1)$$

Onde  $L_{bobina}$  representa a largura da folha de papel.

A escolha das **Variáveis de Secagem** tem conta os mecanismos de transferência de calor e de massa disponíveis, bem como os inputs de controlo da parte de secagem na MP. Neste caso a pressão contida no cilindro Yankee representará a temperatura

Tabela 3.1: Variáveis identificadas para base de dados

Variável	Descrição	Unidade
<b>Variáveis de Processo</b>		
gm	Gramagem	$g/m^2$
$v_{MP}$	Velocidade da Máquina	m/min
crepe	Razão de $v_{MP}$ e da velocidade de enrolamento do papel	%
<b>Variáveis de Secagem</b>		
$H_{in}$	Humidade no início do processo	%
$H_{out}$	Humidade no final do processo	%
$p_Y$	Pressão no Yankee	bar
$T_C$	Temperatura na Campânula	$^{\circ}C$
rpm	Velocidade dos Recirculadores	rpm

da superfície deste; a Temperatura da Campânula será a temperatura do jato sobre o papel; e por fim, a Velocidade dos Recirculadores representará a velocidade do meio de transferência. Seria plausível, do ponto do vista das Redes Neurais, que se escolhessem quaisquer outras variáveis de controlo da MP cuja influência na transferência de calor e de massa fosse equivalente.

É de extrema necessidade definir as condições iniciais para o processo de secagem. Para tal, considerou-se  $H_{in}$ , o teor de humidade do papel no início deste processo. Esta variável representará a fração de água presente na produção quando o papel entra em contacto com o cilindro Yankee.

Como output, foi escolhida a única variável relevante e mensurável, o Teor de Humidade ( $H_{out}$ ). Este é medido por gravimetria no fim do enrolamento das bobinas e é considerado um dos parâmetros de qualidade referente à secagem. Não obstante de representar um parâmetro importante do ponto de vista da produção de papel, este não representa o processo de secagem em termos absolutos. O facto do processo de secagem estar dependente da quantidade de papel produzida leva a que para a criação de um modelo de secagem seja necessário ter em conta a capacidade absoluta deste processo. Sendo assim, é de grande pertinência substituir o Teor de Humidade pelo caudal de massa de água contida no papel após secagem, como exposto na equação 3.2.

$$\dot{m}_{H_2O_{out}} = prod \cdot H_{out} \quad (3.2)$$

É necessário encontrar um balanço mássico de água de forma a poder comparar diferentes condições de secagem e de produção. Para estes efeitos seria interessante encontrar um valor para  $\dot{m}_{H_2O_{in}}$  através do valor de  $H_{in}$ .

Produzir papel, é um processo de eliminação de água ao longo de diferentes estágios sucessivos. Deste modo, a fração correspondente à pasta de papel, na mistura pasta de papel e água, é constante.

Consequentemente, a pasta (material seco) pode ser definida no início da secagem por,

$$pasta = (1 - H_{in}) \cdot prod_{Yankee} \quad (3.3)$$

Sendo  $prod_{Yankee}$  toda a mistura pasta + água no início do processo de secagem, no cilindro Yankee.

Podendo ser calculada da mesma forma no final do processo de secagem por,

$$pasta = prod \cdot (1 - H_{out}) \quad (3.4)$$

Juntando as duas equações obtém-se,

$$prod \cdot (1 - H_{out}) = prod_{Yankee} \cdot (1 - H_{in}) \quad (3.5)$$

De onde se tira que,

$$prod_{Yankee} = \frac{prod \cdot (1 - H_{out})}{1 - H_{in}} \quad (3.6)$$

Sabe-se também que a variável de interesse está dependente de toda a produção que chega ao cilindro Yankee,

$$\dot{m}_{H_2Oin} = prod_{Yankee} \cdot H_{in} \quad (3.7)$$

Substituindo  $prod_{Yankee}$ , a massa de água à entrada do processo de secagem pode ser representada por,

$$\dot{m}_{H_2Oin} = \frac{prod \cdot (1 - H_{out})}{1 - H_{in}} \cdot H_{in} \quad (3.8)$$

Tendo obtido valores para as duas partes do balanço mássico, o valor de água evaporada na secagem é representado pela Taxa de Secagem em 3.9 .

$$TS = \dot{m}_{H_2Oin} - \dot{m}_{H_2Oout} \quad (3.9)$$

No entanto,  $\dot{m}_{H_2Oin}$  é de difícil obtenção, porque do ponto de vista prático há um problema que se levanta na obtenção do valor do teor de humidade no início do processo de secagem. A recolha de amostras na zona do cilindro Yankee ou em qualquer parte da MP é de extrema dificuldade técnica e limitadora, por ser necessário parar a produção de papel.

Neste caso, seria atrativo encontrar um valor médio para este parâmetro, porém, não é aceitável do ponto de vista físico que se considere um valor fixo para este. Tomar esse partido, poderia levar a que a base de dados fosse alimentada de forma errônea, podendo mesmo levar a que se criasse um modelo não capaz de representar o comportamento físico de um processo de secagem.

Para tal, definiu-se um valor para  $H_{in}$  que não fosse constante, mas que fosse concordante com valores admissíveis para este tipo de processo.

### **Método de obtenção do valor do Teor de Humidade à entrada do cilindro Yankee**

A utilização deste método apenas faz sentido, caso não seja possível realizar controlo contínuo da  $H_{in}$ .

Para obter um valor aproximado  $H_{in}$  considera-se que tenha sido já obtida uma Base de Dados relevante para a criação da RN.

De modo a implementar o método, é necessário:

1. Realizar um conjunto de testes em diferentes tipos de condições de produção de modo a obter um valor médio para o teor de humidade no início da secagem, o  $\bar{H}_{in}$ .
2. Calcular o maior valor de TS usando a equação 3.9 tendo em conta o  $\bar{H}_{in}$  obtido a partir dos testes.
3. Realizar a normalização dos vetores correspondentes a cada parâmetro de secagem, a pressão no cilindro Yankee, a Temperatura na Campânula e a velocidade dos Recirculadores, que estão representados por Y, T e R, respetivamente. Após uma normalização individual, é necessário somar os valores normalizados de Y, T e R e tornar a normalizar o vetor obtido pela soma  $YTR_n$ .

$$YTR_n = \frac{Y_n + T_n + R_n}{YTR_{max}} \quad (3.10)$$

4. Pressupor-se que o valor de  $TS_n = 1$  apenas é obtido quando o valor de  $YTR_n$  também é 1. É um pressuposto justificado pelo facto de se considerar que as condições de secagem são o *bottle-neck* do processo de secagem.
5. Orientar a base de dados de modo a que o valor de  $YTR_n$  varie de forma decrescente ao longo de todos os valores.
6. Obter equação descritiva de  $H_{in}$  por dedução matemática através da igualdade entre  $TS_n$  a  $YTR_n$ .

$$TS_n = YTR_n \quad (3.11)$$

onde,

$$TS_n = \frac{TS}{TS_{max}} \quad (3.12)$$

Substituindo TS pela equação 3.9 e usando a igualdade anterior temos,

$$YTR_n = \frac{\dot{m}_{H_2O_{in}} - \dot{m}_{H_2O_{out}}}{TS_{max}} \quad (3.13)$$

Sabendo que  $\dot{m}_{H_2O_{in}}$  e  $\dot{m}_{H_2O_{out}}$  correspondem à equações 3.8 e 3.2, respetivamente, obtemos,

$$YTR_n = \frac{(prod \cdot \frac{1-H_{out}}{1-H_{in}} \cdot H_{in}) - prod(H_{out})}{TS_{max}} \quad (3.14)$$

Ao colocar  $H_{in}$  em evidência obtemos,

$$H_{in} = \frac{YTR_{max} \cdot TS_n + H_{out} \cdot prod}{YTR_{max} \cdot TS_n + prod} \quad (3.15)$$

7. Calcular  $H_{in}$  para cada valor de  $YTR_n$  presente na base de dados.
8. Calcular os valores de TS, tendo em conta o novo valor de  $H_{in}$  e deste modo alimentar a base de dados.

Completando estes passos, é possível obter valores para  $H_{in}$  e consequentemente para TS, de modo a criar a base de dados que alimentará posteriormente a Rede Neuronal.

A base de dados irá agrupar pares de vetores, inputs e outputs, de modo a que a RN reconheça uma relação de causa-efeito entre eles.

$$x = \begin{bmatrix} p_Y \\ T_C \\ rpm \\ prod \end{bmatrix}; y = \begin{bmatrix} TS \end{bmatrix}$$

Base de dados: Confidencial.

### 3.3 Criação do Modelo de Secagem

Os conhecimentos obtidos no capítulo anterior, permitem a criação da RN com as características desejadas para um problema deste tipo. Contudo, a literatura indica uma variedade de parâmetros a serem otimizados. Será, então, necessário efetuar testes à RN a ser criada usando a *toolbox* do MATLAB® para o efeito.

Para efeitos de otimização, é necessária a verificação do número mais favorável de neurónios, da melhor função de transferência para a camada oculta e do melhor algoritmo de treino. Tendo em conta que uma sugestão de (22) para o número ótimo de neurónios seria de  $4n + 1$ , onde n é o número de inputs, basta que seja experimentado para valores dentro de uma gama aceitável. Neste caso foram testados os parâmetros expostos na tabela 3.2.



Tabela 3.2: Testes a realizar à Rede Neuronal

Número de Neurónios	Funções de Transferência	Algoritmos de Treino
1	<i>logsig</i>	Levenberg-Marquardt
⋮		
15	<i>tansig</i>	Bayesian Regulation

Estes parâmetros necessitam ser testados em todas as combinações possíveis, ou seja, testar 15 vezes cada combinação de Algoritmo de Treino + função de transferência.

```
RN=newff(input,target,[1],{'logsig'},'trainlm'); % criação da RN
RN=train(RN,input,target) % treino da RN com o ←
algoritmo escolhido anteriormente
```

Neste exemplo, a camada oculta possui apenas 1 neurónio, é utilizada a função de transferência de logaritmo sigmoidal (*'logsig'*) e o algoritmo de treino de Levenberg-Marquardt (*'trainlm'*). Este código representa apenas um dos valores a ser simulados. É necessário que todas as combinações possíveis sejam testadas de modo a compreender a melhor arquitetura possível.

Para obtenção dos valores calculados pela RN é necessário chamar o comando de simulação da toolbox após efetuado o treino.

```
TS=sim(RN,input); %TS serão os valores simulados com os inputs provenientes ←
da base de dados.
```

Os valores simulados serão comparados com os valores presentes na Base de Dados e será calculada a performance da RN para a arquitetura escolhida.

O critério de escolha para todos os parâmetros a estudar será o valor da Raiz do Erro Quadrático Médio (RMSE) e o valor de Percentagem da Média do Erro Absoluto (MAPE), representados pelas equações 3.16 e 3.17, respetivamente.

$$RMSE = \sqrt{\frac{(\delta_k - \hat{\delta}_k)^2}{kL}} \quad (3.16)$$

$$MAPE = \frac{1}{k} \sum_1^k \frac{(\delta_k - \hat{\delta}_k)^2}{\delta} \quad (3.17)$$

Onde  $\delta_k$  é o desvio dos valores simulados, em relação aos valores presentes na base de dados.

Após a otimização da arquitetura, a RN está pronta a simular novos valores de TS com novas condições de produção e de secagem. Esta simulação permite que sejam escolhidos diferentes parâmetros de secagem com Taxas de Secagem equivalentes. Contudo, para efeitos de poupança energética este modelo não é suficiente, será então necessário adicionar os consumos energéticos associados aos parâmetros de secagem que são controlados pelos operadores da Máquina de Papel.

### 3.4 Redes neuronais em processos mutáveis

O modelo criado através de RN pode não descrever satisfatoriamente o processo em causa. Uma causa possível é o facto de a Base de Dados não abranger suficientemente o espectro de produção, bem como a gama de ação das variáveis de secagem. Outra razão pode ser o facto de se estar perante um processo que se encontre em mutação, e que vá sofrendo alterações que influenciem de determinada forma o comportamento do sistema. Para ambas as hipóteses, é necessário que a RN não seja estática e consequentemente a Base de Dados que a alimenta.

Tendo em conta que a arquitetura da RN já se encontra otimizada, a sugestão é manter a Base de Dados em aberto e sempre que possível adicionar novos dados de produção. A cada novo conjunto de dados invoca-se novamente o comando de treino e a RN criará um novo conjunto de pesos e *biases*.

```
RN=train(RN, inputs, targets) % Treino da Rede Neuronal com comparação entre ↔
    matriz de inputs e targets
```

Sendo o RMSE e MAPE os critérios de performance da RN, este certamente será alterado com o treino de um novo conjunto de dados.

Para que o processo de treino contínuo seja mais simples, sugere-se que seja criada uma aplicação, de modo a facilmente alimentar a RN com novos dados de processo.

### 3.5 Criação do Modelo de Consumos

De forma a complementar o modelo descritivo da secagem foi implementado o modelo de consumos. Basicamente, este modelo descreverá a influência no consumo de Gás Natural e de Energia Elétrica aquando variação dos inputs escolhidos para o modelo de secagem. Não será representativo do consumo global por parte do processo de secagem, pois não tem em conta o consumo dos intervenientes em *stand-by*, mas será representativo para efeitos de comparação de diferentes parâmetros de secagem.

Como referido anteriormente no capítulo 3.3, é possível escolher qualquer variável que seja representativa do fenómeno de secagem para alimentar a Rede Neuronal. Neste caso concreto, foram criadas funções descritivas da pressão no Yankee em função do consumo de Gás Natural; da temperatura escolhida para a Campânula em função do consumo de Gás e das revoluções dos ventiladores de recirculação em função da Energia Elétrica consumida.

Tabela 3.3: Variáveis escolhidas para regressão das funções de custos

Variável	Indicador de Consumo
Pressão no Yankee	$Nm^3/h$ de Gás Natural consumido pela Caldeira
Temperatura na Campânula	$Nm^3/h$ de Gás Natural consumido pelos Queimadores
rpms dos Recirculadores	kW consumidos pelos ventiladores

## Pressupostos

- Na avaliação de consumos do Yankee foi desprezado o consumo GN por parte do processo de *coating* bem como a EE consumida pelo ventilador de combustão e pelas bombas de condensados;
- No consumo por parte da Campânula foi desprezado o consumo de EE por parte dos ventiladores de Combustão e de Extração;
- Para a EE consumida pelos Recirculadores foram adicionados os valores de consumo dos ventiladores de queima da Campânula bem como do ventilador extrator.

### 3.5.1 Consumo do Cilindro Yankee

O cilindro Yankee é alimentado através do vapor produzido pela caldeira, contudo, esta alimenta também o processo de *coating* do cilindro Yankee. Tendo em conta que em termos relativos este consumo é desprezável e que não sofre qualquer alteração aquando da alteração da pressão do Yankee, foi considerado que todo o vapor produzido é utilizado pelo Yankee. O ventilador de combustão funciona de forma contínua e a uma velocidade fixa. O mesmo ocorre com as bombas de condensados e portanto, para efeitos de simplificação do modelo, o consumo de EE associado a estes foi desprezado.

Foi analisado um conjunto de valores, onde a pressão de vapor escolhida pelo operador foi comparada com os valores de consumo de GN registados no mesmo instante no *datalogger* da caldeira. Foi obtido um polinómio capaz de descrever a curva de consumo respetiva.

### 3.5.2 Consumo Térmico da Campânula

O consumo de EE por parte da Campânula ocorre devido à existência de ventiladores de combustão e de recirculação cujo controlo não é efetuado através da escolha da temperatura de trabalho. Tendo em conta que o interesse desta variável é estudar o efeito térmico na secagem de papel, não foram incluídos os consumos dos ventiladores. O método para obtenção da função de consumo por parte da Campânula foi semelhante ao método efetuado com o Yankee, comparando os valores de temperatura escolhidos pelo operador com o consumo de GN.

### 3.5.3 Consumo Mecânico da Campânula

Para o caso dos Recirculadores foi adicionado o consumo dos ventiladores de combustão da Campânula e do ventilador de extração de vapor de água do circuito. Isto porque o seu controlo está dependente do *setpoint* escolhido para os Recirculadores e o efeito físico no processo de secagem é verificado pela variação da velocidade do meio de transferência. Foram registados valores de consumo de Potência Ativa para diferentes *setpoints* de trabalho de modo a cobrir o maior espectro possível do regime de funcionamento.

Com o conjunto de dados foi possível obter uma regressão descritiva do consumo de Energia Elétrica dos Ventiladores de Recirculação.

Tendo as curvas de consumo energético de cada interveniente no processo de secagem é possível representar valores energéticos em valores mais interessantes do ponto de vista industrial e ambiental.

Do ponto de vista industrial, será interessante definir os tarifários energéticos em vigor no instante da simulação e atuar de acordo com a poupança económica.

Na ótica ambiental, tendo em conta o paradigma energético nacional, é possível calcular a intensidade carbónica por emissão de gases com efeito de estufa, de acordo com o previsto na lei pelo Despacho 17313/2008 (23).

### 3.6 Implementação

Com o modelo em RN criado e otimizado, e com as funções de consumo definidas, cabe agora utilizar o modelo para o fim a que se propunha — a poupança energética. Esta combinação de modelos torna possível comparar diferentes conjuntos de parâmetros de secagem, que, embora, tenham Taxas de Secagem semelhantes, poderão ter associados diferentes custos energéticos e económicos.

$$TS = \text{sim}(RN, \text{input});$$

Onde, *sim* representa o comando para simular valores de *TS*, referentes ao vetor *input*, usando a *RN* otimizada e treinada para esses efeito.

$$\text{Custo} = f(\text{input}, \text{tarifa})$$

Onde o Custo associado à secagem são caracterizados por uma função dependente do vetor *input*, que contém todos os parâmetros relevantes para a secagem, e da tarifa dos preços associada à energia consumida por cada parâmetro de secagem.

Do ponto de vista industrial, a TS, apesar de representar o valor absoluto do poder de secagem, peca na ótica do utilizador. É pertinente que seja possível interpretar tais valores de forma a obter uma previsão do parâmetro de controlo de qualidade referente ao processo de secagem. Para tal, foi possível desenvolver uma equação capaz de determinar o Teor de Humidade do papel à saída da MP através dos valores de TS obtidos pelo modelo em RN da secagem.

A dedução está compreendida nas equações que se seguem.

Pela equação 3.9, referente a TS, que contempla 3.8 e 3.2, obtém-se,

$$TS = \text{prod} \cdot \frac{1 - H_{out}}{1 - H_{in}} \cdot H_{in} - \text{prod} \cdot H_{out} \quad (3.18)$$

Pondo  $H_{out}$  em evidência,

$$H_{out} = \frac{(H_{in} - 1) \cdot TS + \text{prod} \cdot H_{in}}{\text{prod}} \quad (3.19)$$

Neste momento, todos os requisitos necessários à implementação do modelo foram obtidos, e portanto, cabe agora implementa-los de forma a facilitar o seu uso.

### 3.6.1 Ferramenta GUI

Para que seja mais acessível a utilização de todas as valências das RN e da conjugação dos modelos de secagem e de custos, foi desenvolvida uma ferramenta GUI (*Graphical User Interface*) em ambiente MATLAB®.




Figura 3.2: Fluxograma de implementação do *Drying Efficiency Simulator*

Com esta aplicação, o utilizador terá à disposição 3 separadores. Um para Redes Neurais, outro para Funções de Custos e o final para Simulação.

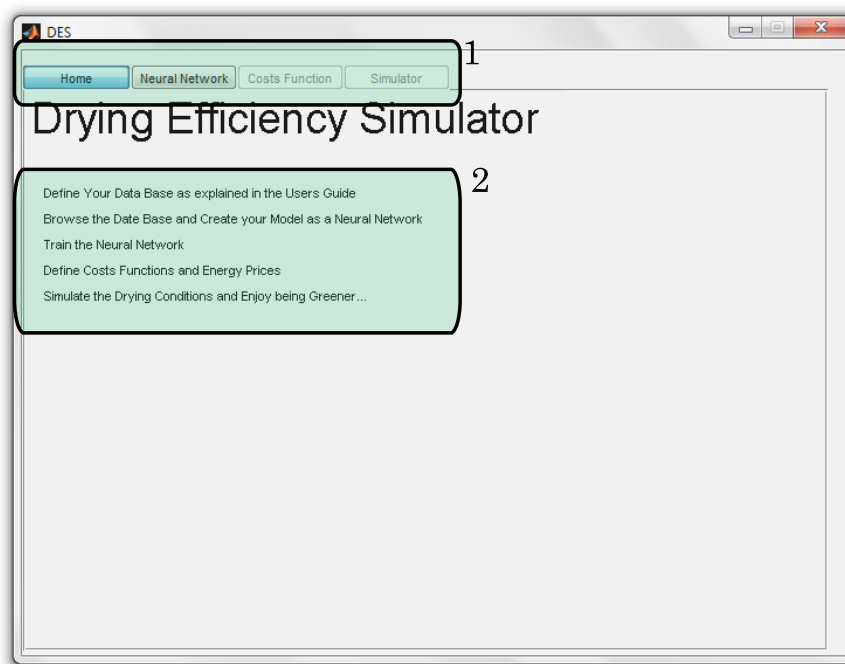


Figura 3.3: Página de apresentação da aplicação

1. Separadores para navegação dentro da aplicação;
2. Breve descrição dos passos a seguir de modo a configurar e desenvolver um modelo de secagem.

Na figura 3.3 está representada a página inicial da aplicação, esta página é meramente explicativa da sequência de passos a efetuar possibilitando ao utilizador simular diferentes cenários de produção.

### Separador das Redes Neurais

A partir daqui, o utilizador tem à sua disposição apenas o separador responsável pela criação do modelo através de redes neuronais, estando todos os outros inativos para que as etapas sejam efetuadas na sequência pretendida.



Figura 3.4: Página para criação do modelo através de Redes Neurais

1. Botões responsáveis por fazer *upload* da base de dados, criar a Rede Neuronal e Treina-la;
2. Zona de performance onde o utilizador tem acesso ao RMSE calculado e à propagação do erro ao longo da produção.

Este separador, 3.4 e 3.5, pode ser considerado o cérebro da aplicação, daí que nele que se encontram as redes neuronais que serão responsáveis pela criação do modelo de secagem.

Há 3 passos a cumprir neste separador antes de avançar para os próximos.

1. Botão “Browse” - A partir do qual será exposta uma nova janela que permitirá carregar a base de dados do computador que irá alimentar a RN;

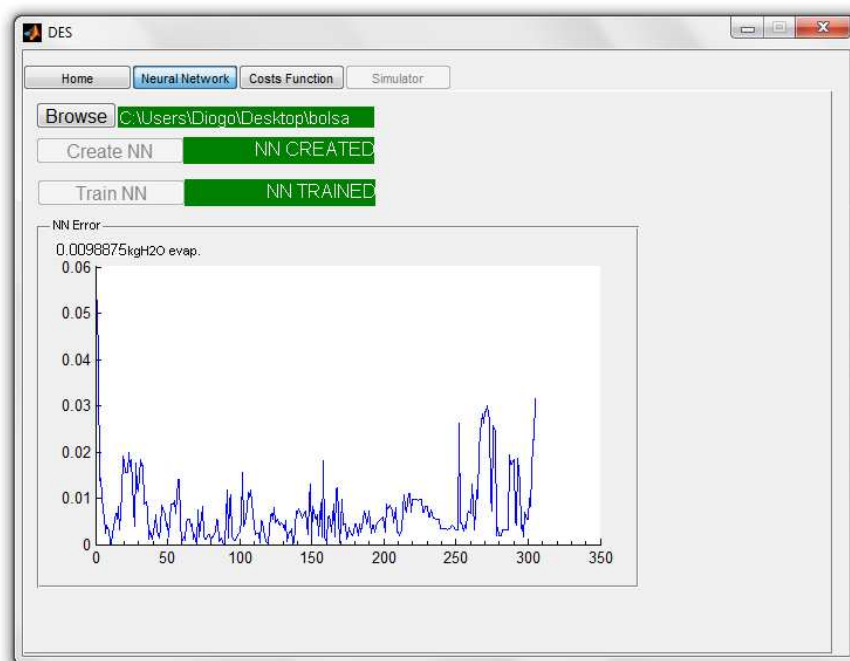


Figura 3.5: Página para criação do modelo através de Redes Neurais após configuração

2. Botão “Create NN” - Aqui é criada a RN tendo em conta a otimização da arquitetura já efetuada;
3. Botão “Train NN” - Através daqui será treinada a rede neuronal; será calculado o erro e será preparado o modelo de secagem.

Completando estes passos, o modelo de secagem fica criado. Porém, antes de prosseguir para a simulação, é necessário definir as curvas de consumo dos intervenientes da secagem no próximo separador (Figura 3.6).

### Separador do Modelo de Custos

1. Tabela onde serão introduzidos os índices referentes aos polinómios descritivos das funções de consumo; Botão para aceitar as variáveis acima inseridas;
2. Aqui o utilizador deve escolher o preço da Energia Elétrica e do Gás Natural.

Os polinómios representativos das curvas de consumo, obtidas a partir da metodologia explicada anteriormente em 3.5, podem ser inseridos na tabela criada para o efeito. Nesta tabela, devem ser colocados os índices de até a polinómios de 3ª ordem.

Para além de ser preciso definir as funções que definem o modelo de consumos, é também necessário indicar os preços da energia associada. Com esta opção, será possível comparar diferentes cenários, tendo em conta a alteração de tarifários, bem como diferentes paradigmas de modelos energéticos.

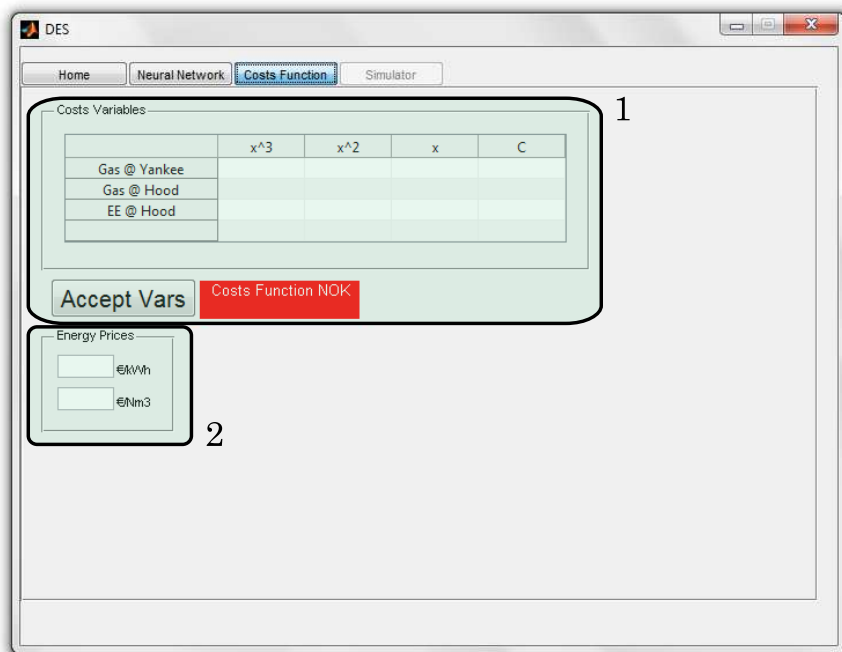


Figura 3.6: Página para introdução das curvas de consumo e preços da energia

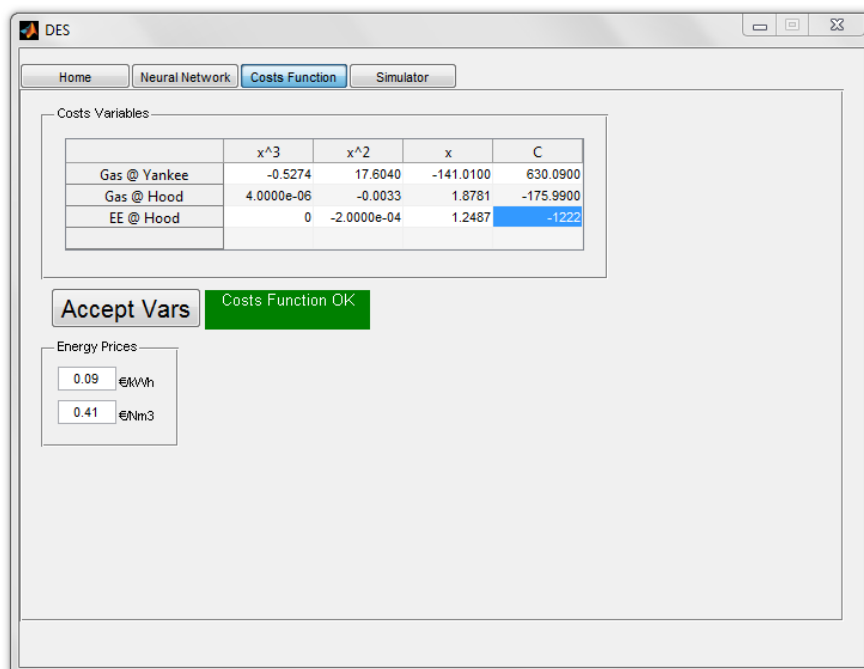


Figura 3.7: Página para introdução das curvas de consumo e preços da energia após configuração



## Separador do Simulador

Por fim, o modelo de custos de secagem já se encontra pronto a ser utilizado no separador "Simulator" apresentado na Figura 3.8.

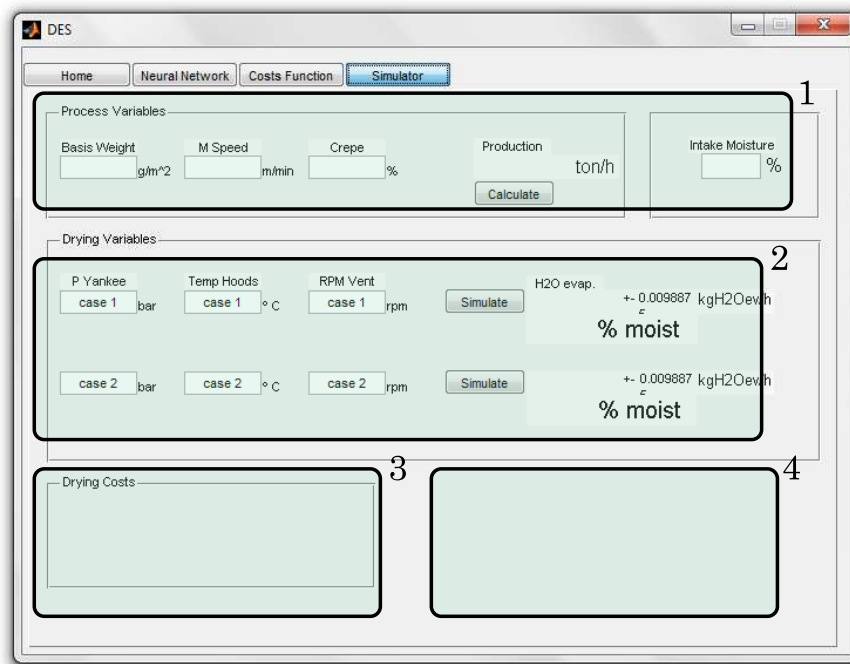


Figura 3.8: Página para simulação do modelo de custos de secagem

1. Zona das variáveis de processo, onde o utilizador define a produção ou os parâmetros produtivos e o simulador calcula a produção; Aqui também é definida o teor de humidade à entrada do processo de secagem  $H_{in}$ ;
2. Aqui o utilizador deve escolher dois conjuntos de variáveis de secagem de modo a poder comparar a simulação do *case1* com o *case2*;
3. Mostrador do custo específico relativo à secagem de cada cenário;
4. Indicador de se o utilizador se encontra numa situação de poupança e de quanto mais ou menos  $\text{kgCO}_2\text{eq/h}$  e €/ton está associado ao caso 2.

The screenshot shows the DES software interface with the 'Simulator' tab selected. The 'Process Variables' section includes input fields for Basis Weight (xx g/m²), M Speed (xxx m/min), Crepe (xxx %), Production (ton/h), and Intake Moisture (XX %). A 'Calculate' button is present. The 'Drying Variables' section includes input fields for P Yankee (x bar), Temp Hoods (xxx °C), RPM Vent (xxxx rpm), and two 'Simulate' buttons. The output shows H2O evap. as +- 0.009887 kgH2Oew/h and % moist. The 'Drying Costs' section shows CASE 1 and CASE 2 as €/ton, with a green checkmark indicating a savings situation. The final output shows kgCO2eq/h and €/ton.

Figura 3.9: Página para simulação do modelo de custos de secagem em situação de poupança

The screenshot shows the DES software interface with the 'Simulator' tab selected. The 'Process Variables' section includes input fields for Basis Weight (xx g/m²), M Speed (xx m/min), Crepe (xx %), Production (ton/h), and Intake Moisture (XX %). A 'Calculate' button is present. The 'Drying Variables' section includes input fields for P Yankee (x bar), Temp Hoods (xxx °C), RPM Vent (xxxx rpm), and two 'Simulate' buttons. The output shows H2O evap. as +- 0.009887 kgH2Oew/h and % moist. The 'Drying Costs' section shows CASE 1 and CASE 2 as €/ton, with a red X indicating a counter-savings situation. The final output shows kgCO2eq/h and €/ton.

Figura 3.10: Página para simulação do modelo de custos de secagem em situação de contrapoupança

Este é sem dúvida o separador mais interessante de toda a aplicação. Nele será possível simular dois cenários com diferentes condições de secagem para um conjunto fixo de parâmetros de produção. Com a simulação, o utilizador recebe como informação:

- A previsão da Taxa de Secagem;
- A previsão da humidade no papel à saída da máquina;
- O custo específico associado à secagem;
- A diferença dos custos entre o caso 1 e 2;
- A diferença na quantidade de  $kgCO_2eq/h$  emitida entre o caso 1 e 2.

Com estes dados, o utilizador pode optar por cenários de secagem mais amigos do ambiente e mais económicos.

### 3.7 Síntese e Conclusões do capítulo

Este capítulo é o afunilamento do capítulo anterior, onde os conceitos acerca das Redes Neurais são aplicados no caso de estudo concreto.

Aqui é definido e explicado em que consiste o objeto de estudo, é explicado todo o método de obtenção de dados e o seu tratamento.

São escolhidas as variáveis relevantes para modelação do processo de secagem, e é desenvolvida uma metodologia para obtenção da Base de Dados, onde se cria um método que possibilita a aproximação de uma variável importantíssima — o Teor de Humidade no início do processo de secagem.

É mostrada a programação por detrás da criação do modelo. É exposta a problemática de validação da Arquitetura da Rede, bem como, o método de escolha dos parâmetros que a definem. A partir daí é definido um conjunto de testes a realizar à Rede Neuronal, de modo a se atingir a melhor arquitetura possível.

Tendo em conta, a evolução dos processos como é este caso, explicou-se que existe a hipótese de realimentar a Rede Neuronal, sempre que exista um novo conjunto de dados, e assim, manter esta actualizada em relação ao processo.

Foi exposto, o método de desenvolvimento do modelo de consumos, dos intervenientes da secagem. As 3 variáveis, escolhidas como controladoras da intensidade de secagem foram sujeitas a uma análise, da qual, surgiram 3 curvas de consumo relativas às escolhas definidas na Máquina de Papel.

Por fim, mas não menos importante, é apresentada a ferramenta informática desenvolvida em MATLAB®, cujo objetivo é tornar mais acessível a implementação destes conceitos. É mostrada uma visita ao longo dos separadores da ferramenta, a qual permite: descarregar uma base de dados; criar e treinar uma Rede Neuronal; definir as funções de custos; e simular novos cenários do processo de secagem.

Com esta ferramenta, o utilizador é sensibilizado, acerca das escolhas que pretende realizar ao nível dos parâmetros de secagem, de modo a realizar as escolhas mais económicas e amigas do ambiente.



Parte III

Resultados, Discussão e  
Conclusão



## Capítulo 4

# Resultados

### 4.1 Introdução

Neste capítulo serão expostos e analisados os resultados da abordagem feita no capítulo anterior. Será analisada a escolha da arquitetura da RN; será analisada a obtenção das funções de consumo para os intervenientes no processo de secagem; também serão discutidos dados provenientes da aplicação de suporte à RN; e por fim, mas não menos importante, serão expostos diferentes casos de condições de secagem que visem a poupança energética.

### 4.2 Análise da Arquitetura da Rede Neuronal

Segundo a abordagem do Capítulo 3 ficou explícito que seria necessário calcular o erro após treinada a RN com os diferentes tipos de arquitetura. Havendo dois algoritmos de treino (Levenberg & Marquardt e Bayesian Regulation) e duas funções de transferência (Logaritmo Sigmoidal e Tangente Hiperbólica Sigmoidal) a testar de 1 a 15 neurónios na camada oculta, obteve-se um total de 60 simulações com o cálculo dos respetivos erros.

#### 4.2.1 Algoritmo de Treino Levenberg & Marquardt

Na tabela 4.1 estão expostos os valores de RMSE e de MAPE para as arquiteturas cujo algoritmo de treino é LM. A destacado encontram-se os melhores valores de RMSE e MAPE para cada função de transferência. A melhor arquitetura é aquela que tem 15 neurónios na camada oculta com o tangente hiperbólica sigmoidal como função de transferência. Para esta arquitetura ambos os parâmetros de verificação são os mais baixos, obtendo-se um valor de RMSE de 0.0556 kg/h, o qual representa em percentagem um MAPE de 0.00066494 %. Para o caso da função de transferência logaritmo sigmoidal, o melhor valor de erro verifica-se quando se tem 8 neurónios na camada oculta.

Tabela 4.1: RMSE e MAPE para Algoritmo de **Levenberg & Marquardt** com as possíveis combinações de arquiteturas

Nº de Neurónios	<i>logsig</i>		<i>tansig</i>	
	RMSE (kg/h)	MAPE (%)	RMSE (kg/h)	MAPE (%)
1	2.5996	0.0369	1.5188	0.0216
2	1.9536	0.0299	1.1566	0.0170
3	1.5366	0.0216	0.8125	0.0108
4	0.3441	0.0046	0.1215	0.0017
5	1.3939	0.0181	0.2025	0.0027
6	0.3759	0.0054	0.1529	0.0021
7	0.0961	0.0013	0.4614	0.0060
8	<b>0.0646</b>	<b>0.0008524</b>	0.0947	0.0013
9	0.2286	0.0032	0.4565	0.0064
10	0.3265	0.0039	0.1634	0.0020
11	0.1574	0.0021	0.1175	0.0016
12	0.6558	0.0087	0.1455	0.0018
13	0.4412	0.0045	0.4422	0.0038
14	0.1582	0.0022	0.3515	0.0049
15	0.8162	0.0111	<b>0.0556</b>	<b>0.00066494</b>




Figura 4.1: Gráfico da evolução do RMSE para as duas funções de transferência



No gráfico referente ao RMSE, da Figura 4.1, é possível observar que, tal como esperado, aumentando a complexidade da RN, a capacidade de esta simular valores mais próximos da base de dados também é melhorada, atingindo o mínimo quando se encontram 15 neurónios na camada oculta para a função de transferência 'tansig'.

Comparando as duas funções de transferência, pode observar-se que partilham, de certa forma, a mesma evolução de comportamento. Contudo, para a função de 'logsig' o valor de erro diminui gradualmente atingindo um mínimo rapidamente com 8 neurónios invertendo a monotonia e aumentando gradualmente o erro após a arquitetura ótima.

Para a função 'tansig', apesar de obter um mínimo relativo com 8 neurónios, este valor não é o menor em todo o domínio, atingindo por fim o menor valor de erro para este Algoritmo de treino com 15 neurónios. Como por vezes arquiteturas mais complexas (i.e. mais neurónios) levam a modelos menos aptos na previsão em problemas de generalização, será necessário estudar as diferenças entre as arquiteturas com os neurónios 8 e 15 desta função.




Figura 4.2: Gráfico da evolução do MAPE para as duas funções de transferência

Na comparação de valores do erro MAPE, pode-se observar uma correlação monotónica idêntica com o observado no estudo do RMSE, onde os melhores valores de erro ocorrem com as mesmas arquiteturas que no caso anterior.

#### 4.2.2 Algoritmo de Treino Bayesian Regulation

Para o caso do algoritmo BR, a tabela com os erros calculados, Tabela 4.2, mostra que, tanto para valores de RMSE como para valores de MAPE, a melhor arquitetura

ocorre com 4 neurónios, com a função de transferência Tangente Hiperbólica Sigmoidal com os valores de 0.0056 kg/h e de 0.000071897 %, respetivamente.

Ambas as funções de transferência atingem mínimos de erro muito proximamente e em arquiteturas extremamente simples, onde o número de neurónios é igual ou inferior ao número de inputs (i.e. nº inputs igual a 4). Esta simplicidade de RN pode levar a um bom comportamento de generalização que será estudado no decorrer desta análise.

Tabela 4.2: RMSE e MAPE para Algoritmo de **Bayesian Regulation** com as possíveis combinações de arquiteturas

Nº de Neurónios	<i>logsig</i>		<i>tansig</i>	
	RMSE (kg/h)	MAPE (%)	RMSE (kg/h)	MAPE (%)
<b>1</b>	0.1497	0.0021	0.2064	0.0029
<b>2</b>	0.2251	0.0032	0.0448	0.0006
<b>3</b>	<b>0.0104</b>	<b>0.00014219</b>	0.0269	0.0004
<b>4</b>	0.0201	0.0003	<b>0.0056</b>	<b>0.000071897</b>
<b>5</b>	0.6276	0.0087	0.4125	0.0057
<b>6</b>	0.5219	0.0074	0.2995	0.0042
<b>7</b>	0.5185	0.0073	0.4363	0.0062
<b>8</b>	0.4891	0.0070	0.334	0.0048
<b>9</b>	0.3951	0.0057	0.3564	0.0051
<b>10</b>	0.3934	0.0055	0.3214	0.0045
<b>11</b>	0.3462	0.0047	0.2716	0.0039
<b>12</b>	0.4458	0.0063	0.2983	0.0040
<b>13</b>	0.4226	0.0058	0.2605	0.0035
<b>14</b>	0.4199	0.0061	0.2477	0.0036
<b>15</b>	0.3787	0.0053	0.2264	0.0031

No gráfico da Figura 4.3 é possível observar os resultados do cálculo do RMSE para o algoritmo de treino Bayesian Regulation. Neste caso, e comparando com o algoritmo de treino LM, é evidente que a RN se comporta melhor, com arquiteturas mais simples, com o número de neurónios inferior a 4 e independentemente da função de transferência escolhida para a camada oculta. É possível se constatar também que a evolução do erro é muito mais monotónica para este algoritmo de treino justificada pela utilização do parâmetro de controlo da evolução de treino, o erro quadrático médio com regularização.

O erro MAPE sofre uma evolução ao longo do aumento do número de neurónios exatamente igual à observada com o erro RMSE. Este facto deve-se ao forte poder de generalização deste algoritmo.




Figura 4.3: Teste de Arquitetura com o Algoritmo de Treino Bayesian Regulation




Figura 4.4: Gráfico comparativo da evolução do MAPE para as duas funções de transferência escolhidas

A melhor arquitetura para cada algoritmo de treino será testada de forma a observar a capacidade de generalização de cada uma. Esta análise será exposta no capítulo a jusante.

### 4.2.3 Análise da Capacidade de Generalizar

O valor do coeficiente de regressão ( $R$ ) é utilizado para observar a correlação de valores calculados com os valores presentes na base de dados. Neste caso esta verificação perde relevância, pois o valor de  $R$  para as arquiteturas com menor erro é igual a 1.

Uma forma de verificar este parâmetro muito importante do ponto de vista operacional é analisar o erro particularmente, percorrendo um varrimento da base de dados comparando os valores de desvio  $\delta$ .

Para efeitos de validação da melhor arquitetura observada anteriormente, comparou-se a melhor arquitetura do algoritmo LM com a melhor arquitetura do algoritmo BR.

#### Arquitetura: 15 neurónios, Tangente Hiperbólica Sigmoidal e Levenberg & Marquardt

Na análise do gráfico com os valores de desvio  $\delta$  em função da produção para a melhor arquitetura com o algoritmo de treino LM, é possível observar que há uma fraca homogeneização dos valores de desvio. Contudo, uma análise mais cuidada mostra que existe uma certa dispersão de alguns valores de desvio, o que pode representar um problema de generalização.

O ponto com maior produção é também o que possui maior valor de desvio, com o valor de 0.4126 kg/h que representa ser 7,5x superior a valor de RMSE.




Figura 4.5: Gráfico referente ao  $\delta$  em função da produção

#### Arquitetura: 4 neurónios, Tangente Hiperbólica Sigmoidal e Bayesian Regulation

É possível observar que a propagação do erro ao longo da produção é praticamente desprezável. Tendo em conta a escala do erro observada no gráfico da Figura 4.5, o valor de  $\delta$  encontra-se extremamente condensado e próximo de zero.




Figura 4.6: Gráfico referente ao  $\delta$  em função da produção

O facto de não existir um grande desfazamento de valores de  $\delta$  ao longo do gráfico, mostra que os resultados são homogêneos entre si. Neste gráfico não são observados valores demasiado desfasados do conjunto o que sugere uma boa capacidade de generalização para esta arquitetura.

Analisando os resultados holisticamente, pode afirmar-se que a melhor arquitetura para a criação deste modelo é aquela que é treinada através do algoritmo de treino Bayesian Regulation — possui 4 neurónios na camada oculta, com a função de transferência Tangente Hiperbólica Sigmoidal.

### 4.3 Estudo do comportamento do Modelo de Secagem

Tendo a arquitetura em RN bem definida, é possível observar agora o comportamento do modelo. Para tal, fixar-se-ão valores de produção e a partir daí, provocar-se-á a variação dos parâmetros de secagem individualmente, de modo a observar a influência destes na Taxa de Secagem, e consequentemente, na previsão do valor de  $H_{out}$ .

Para efeitos de teste fixou-se o valor de produção e o teor de humidade do papel à entrada do processo de secagem ( $H_{in}$ ) para os 3 casos que se seguem, sendo 3,4 ton/h e 60 %, respetivamente.

No Apêndice B, encontram-se simulações referentes a diferentes níveis de produção, 4 ton/h e 4.6 ton/h. Deste modo é varrido todo o espectro de produção. A análise a jusante aplica-se ao gráficos presente no apêndice, visto se observar um comportamento semelhante do modelo de secagem.

Nas Figuras 4.7, 4.8 e 4.9, verifica-se um comportamento aproximadamente linear da influência de cada parâmetro de secagem no teor de humidade do papel à saída da máquina. Para cada caso, apenas um parâmetro de secagem é alterado de cada vez, mantendo tudo o resto constante.




Figura 4.7: Comportamento do Modelo de Secagem variando a pressão do cilindro *Yankee*.

O gráfico da Figura 4.7 reflete a influência da pressão do cilindro Yankee na previsão do Teor de Humidade. Variou-se a pressão do vapor saturado no interior do cilindro Yankee entre 4.5 bar e 7.5 bar. E fixou-se a Temperatura da Campânula e a velocidade dos Recirculadores em  $270^{\circ}\text{C}$  e 1650 rpm. Verifica-se um máximo de  $H_{out}$  igual a 9.66 % com o menor valor de pressão. A simulação foi parada quando os valores do Teor de Humidade atingem o zero. Os valores próximos de zero, embora que matematicamente sejam aceitáveis visto que se aumenta o poder de secagem, não o são se tivermos em conta o limite físico da secagem o Teor de Humidade de equilíbrio. Após este ponto não é possível secar mais o material, no entanto a Rede Neuronal é cega e carece de informação para definir esse ponto.

No gráfico da Figura 4.8 foi investigado o efeito da temperatura da Campânula no valor de  $H_{out}$ . Neste caso é mantida a pressão do cilindro *Yankee* a 5 bar e a velocidade dos recirculadores a 1650 rpm. A gama de temperaturas estudada foi de  $240^{\circ}\text{C}$  a  $500^{\circ}\text{C}$ .

9.48 % foi o maior valor de  $H_{out}$  registado. Também neste caso se verificou a ocorrência da simulação representada no gráfico da Figura 4.7 em relação ao valor mínimo do Teor de Humidade. No entanto pode-se considerar uma previsão verosímil pelo facto de se tratar de uma simulação onde a produção não é elevada e, desta forma, o poder de secagem disponível, promovido pela Campânula, é suficiente para que simulação saia dos valores aceitáveis de Teor de Humidade.

Por fim, estudou-se a influência dos ventiladores na secagem do papel. No gráfico da Figura 4.9 estão expostos os valores de  $H_{out}$  quando temos valores fixos para os parâmetros de secagem. A pressão do cilindro *Yankee* é 5 bar e a temperatura é  $270^{\circ}\text{C}$  e a velocidade dos recirculadores varia entre 1600 rpm e 1950 rpm.




Figura 4.8: Comportamento do Modelo de Secagem variando a temperatura da Campânula




Figura 4.9: Comportamento do Modelo de Secagem variando as RPM dos Recirculadores

O maior valor de Teor de Humidade calculado é igual a 8.64%; e o menor é atingido na velocidade máxima dos ventiladores sendo igual a 4.05 %. Neste exemplo o poder dos ventiladores não é suficiente para que a simulação do  $H_{out}$  saia de valores credíveis visto não se aproximar de zero. Tendo em conta a gama de funcionamento deste parâmetro, pode-se concluir, que este é o parâmetro onde a influência é menor na ótica da secagem

Em todos os casos acima investigados, foram escolhidas as gamas dos parâmetros de secagem definidas pelo construtor da máquina de papel.

#### 4.3.1 Estudo do efeito do Método 3.2

De forma a averiguar-se a influência de  $H_{in}$  nos valores de Teor de Humidade simulados, foi encontrado o erro MAPE deste parâmetro para 2 cenários:

**Caso 1** Considerar o valor de  $H_{in}$ , o valor obtido através do método exposto em 3.2 para cada entrada da base de dados e com esses valores treinar a Rede Neuronal;

**Caso 2** Considerar o valor de  $H_{in}$  constante e igual à média obtida nos testes realizados ao teor de Humidade no início do processo de secagem e realizar o treino da Rede Neuronal com esse valor.

##### Caso 1

Obteve-se um valor para o MAPE igual a  $2.0194 \cdot 10^{-7} \%$ . Este valor foi calculado através da equação 3.17, mas desta vez comparando os valores de Teor de Humidade presentes na base de dados com os respetivos valores calculados a partir do modelo criado com as Redes Neuronais e da equação 3.19.

O comportamento deste modelo dentro de valores não presentes na base de dados, como mostrado nas Figuras 4.7, 4.8 e 4.9, é aceitável e corresponde ao esperado numa operação de secagem. Isto é, para valores mais elevados de parâmetros de secagem e caso se mantenha tudo o resto constante, evapora-se uma maior quantidade de água e obtêm-se valores inferiores de Teor de Humidade.

No Apêndice A, estão disponíveis os valores do teste de *secciccate* realizado à prensa aspirante que se encontra a montante do cilindro *Yankee*. Nesse teste, determinaram-se experimentalmente os valores do teor de humidade  $H_{in}$  para diferentes tipos de produção. Em suma os valores de interesse são:

Tabela 4.3: Teste de *secciccate* à prensa

	<i>Mín</i>	<i>Med</i>	<i>Máx</i>
$H_{in}$ (%)	59.5	61.2	63.8

A partir do método 3.2 foi definido um valor de  $H_{in}$  para cada entrada da base de dados. O gráfico da Figura 4.10 demonstra a evolução deste valor ao longo da produção.

Analisando o gráfico, observa-se que existem valores fora dos limites definidos no teste de *secciccate*. No entanto, essa dispersão não se torna relevante visto que a diferença entre o menor valor calculado e menor valor recolhido é de cerca de 1 %, sendo este valor, provavelmente, inferior ao erro provocado na recolha de amostras durante este teste.






Figura 4.10: Evolução do  $H_{in}$  obtido através do método 3.2 ao longo da produção

## Caso 2

O Teor de Humidade no início da secagem,  $H_{in}$ , foi fixado em 61.2 %, sendo o valor médio obtido a partir dos testes presentes no Apêndice A. O valor de MAPE para a previsão do Teor de Humidade é  $6.1 \cdot 10^{-3} \%$ , que apesar de ser um valor bastante aceitável do ponto de vista físico, leva o modelo comportar-se de modo não aceitável no que toca à previsão de valores fora da base de dados.




Figura 4.11: Comportamento do Modelo de Secagem variando a pressão do cilindro *Yankee* com  $H_{in}$  fixo

Nos gráficos das Figuras 4.11, 4.12 e 4.13 é possível observar que o comportamento está longe do esperado, revelando mesmo a falta de influência dos parâmetros de secagem no teor final de humidade ( $H_{out}$ ).

Como se pode constatar pelo gráfico da Figura 4.11, ao fixar-se o  $H_{in}$ , embora que para um valor médio, o modelo perde capacidade de responder fisicamente ao aumento da pressão no cilindro *Yankee*. Simulando novos valores, de acordo com o gráfico da Figura 4.7, observa-se que o  $H_{out}$  não sofre alteração significativa de acordo com que seria de esperar numa operação de secagem. Entre 5.1 e 7 bar, verifica-se um decréscimo no  $H_{out}$  de 2.06 para 1.58 %. Sendo esta a única gama de valores que se comporta monotonamente de acordo com a realidade da secagem, pode-se considerar que esta simulação carece de interesse prático.




Figura 4.12: Comportamento do Modelo de Secagem variando a temperatura da Campânula com  $H_{in}$  fixo

No gráfico da Figura 4.12, com o aumento da temperatura da Campânula, a simulação demonstra ter um comportamento decrescente no que toca à evolução do teor de humidade. Não obstante, o resultado levanta algumas dúvidas, visto que, apesar de se aumentarem  $260^{\circ}\text{C}$  na temperatura da Campânula, apenas se verifica uma diminuição de 2.11 para 1.59 % no teor previsto para o teor de humidade ( $H_{out}$ ).

Para o gráfico da Figura 4.13, pode-se considerar que o efeito do aumento da velocidade dos Recirculadores não tem qualquer efeito na TS e consequentemente no teor de humidade final do papel. Do ponto de vista físico, esta constatação não pode ser considerada, sendo a velocidade do meio de transferência, um fator importantíssimo no que toca aos modelos de secagem baseados em fenómenos físicos.

Com este conjunto de resultados, é justificado o desenvolvimento e utilização do método 3.2. Constata-se também que o valor de  $H_{in}$  é extremamente importante na modelação de um processo de secagem desta envergadura, contudo o método de amostragem pode levar a erros insustentáveis do ponto de vista de modelação.




Figura 4.13: Comportamento do Modelo de Secagem variando as RPM dos Recirculadores com  $H_{in}$  fixo

## 4.4 Análise do modelo de consumos

De acordo com a metodologia explicada na secção 3.5, foram criadas 3 bases de dados (conteúdo confidencial), a partir das quais foram obtidas funções de consumo para as variáveis influentes na secagem.

### 4.4.1 Consumo do Cilindro Yankee

No gráfico da Figura 4.14 está exposta a regressão de valores referente ao consumo de GN por parte da caldeira em função da pressão do cilindro Yankee.

Neste caso, foram analisados 452 valores de consumo em função da pressão escolhida pelo operador para o cilindro secador Yankee. Os valores de pressão variaram entre os 5 bar e os 7.6 bar e foram recolhidos entre os meses de maio e julho do ano 2012.

Através desta análise obteve-se uma regressão cúbica da curva de consumo da caldeira com um  $R^2 = 0.9791$ , sendo o polinómio representado pela equação 4.1:

$$\dot{v}_Y = -0.5274 \cdot p_Y^3 + 17.604 \cdot p_Y^2 - 141.01 \cdot p_Y + 630.09 \quad (4.1)$$

Sendo  $\dot{v}_Y$  o caudal volúmico em  $Nm^3/h$  e  $p_Y$  a pressão do cilindro Yankee.

O valor aceitável de  $R^2$  para esta regressão, oferece alguma confiança na previsão de novos valores de consumo em função do *setpoint* escolhido.

### 4.4.2 Consumo Térmico da Campânula

Seguindo o mesmo tipo de abordagem, neste caso o consumo de gás por parte dos queimadores de gás natural presentes na Campânula. No total, existem 2 queimadores




Figura 4.14: Regressão do consumo de gás natural em função da pressão do cilindro Yankee

independentes de cada lado da campânula como explicado no capítulo 3, no entanto, para efeitos de modelação foram englobados os consumos de ambos e tratados como um só. Esta aproximação é válida, visto que o histórico de produção reporta um controlo conjunto da temperatura escolhida para a Campânula.




Figura 4.15: Regressão do consumo de gás natural em função da temperatura dos queimadores da Campânula

No gráfico da Figura 4.15 está exposta a correlação de valores de consumo de GN obtida através da leitura dos *dataloggers* dos queimadores da Campânula, com a escolha de Temperatura por parte do operador.

Um total de 393 valores foram recolhidos, também entre os meses de maio e julho de 2012. A base de dados obtida compreende valores de temperatura entre os  $250^{\circ}\text{C}$  e os  $495^{\circ}\text{C}$ .

Foi definida uma regressão cúbica entre os valores em estudo e obteve-se um  $R^2 = 0.9973$  que representa um forte correlacionamento da temperatura em função dos consumos registados.

A equação 4.2 representa o polinómio descritivo da curva de consumo da parte térmica da Campânula.

$$\dot{v}_C = 4 \cdot 10^{-6} \cdot T_C^3 - 0.0033 \cdot T_C^2 + 1.8781 \cdot T_C - 175.99 \quad (4.2)$$

No qual o consumo em  $\text{Nm}^3/\text{h}$  é representado por  $\dot{v}_C$  e a temperatura escolhida pelo operador por  $T_C$ .

#### 4.4.3 Consumo Elétrico da Campânula

No caso dos ventiladores, visto não existir registo em tempo real por parte do sistema de controlo, foi necessário retirar valores de Potência Ativa a partir dos VEV que os controlam, registando-se 36 valores de entrada para a base de dados.

No gráfico que se segue, Figura 4.16, é possível observar a variação da potência ativa em função dos valores de rpm escolhido pelo operador.




Figura 4.16: Regressão do consumo de Energia Elétrica em função das rpm escolhidas

Com esta dispersão de valores, foi obtido um  $R^2 = 0.9713$  com um polinómio de regressão de 2ª ordem — equação 4.3. É possível observar que o controlo dos ventiladores de circulação tem menor resolução, comparando com o controlo do cilindro Yankee e

com a parte térmica da Campânula. Também é clara uma variação da potência ativa em torno de cada *setpoint* de RPM. Verificou-se alguma correlação deste acontecimento com o *setpoint* de temperatura. Isto é, para temperaturas inferiores observou-se um consumo superior nos ventiladores; este facto é provavelmente explicado pela variação da densidade do ar. No entanto, não foi possível criar uma correlação matemática. Apesar deste facto se verificar, para efeitos de previsão de consumo em condições de igual temperatura esse efeito é desprezável visto que se comporta como um *offset*.

Na equação 4.3, está representado o polinómio de segunda ordem representativo da curva do somatório da potência ( $P_{act}$ ) de todos os ventiladores em função da escolha de velocidade nos ventiladores de recirculação (rpm).

$$P_{act} = -2 \cdot 10^{-4} \cdot rpm^2 + 1.2487 \cdot rpm - 1222 \quad (4.3)$$

Neste caso, devido ao comportamento quasi-linear da correlação, uma regressão de ordem 2 conferiu uma melhor aproximação.

Deste modo foram obtidas, 3 curvas de consumo de energia por parte dos intervenientes da secagem. Em suma, as curvas representam o modelo de consumos, do qual será possível obter os consumos de GN e EE, a intensidade carbónica e os custos económicos relativos ao processo de secagem.

## 4.5 Análise de valores de produção através da GUI

Com a implementação dos modelos (modelo de secagem e modelo de custos) na GUI criada para o efeito, tornou-se mais acessível comparar diferentes tipos de produção, e também diferentes conjuntos de parâmetros de secagem de modo a obter valores mais atrativos no que respeita ao consumo energético.

Para efeitos de comparação nesta análise, serão utilizados os valores calculados para a intensidade carbónica de cada caso. Mesmo sendo um fator dependente do país em questão do ponto de vista da intensidade carbónica definida para a energia elétrica, aparenta ser um valor mais transversal para efeitos de comparação.

O paradigma da Energia Elétrica de Portugal no decorrer desta dissertação era regido pelo Despacho 17313/2008 (23), onde o fator de emissão associado ao consumo de eletricidade era igual a  $0.47 \text{ kgCO}_2\text{e/kWh}$ .

Como base de análise serão expostos 2 casos de produção e condições de secagem bem definidas e conhecidas pelos operadores. Para estes testes teve-se em conta escolher tipos de produto que tivessem uma janela temporal de produção o mais alargada possível e, deste modo, permitir estabilizar a máquina com os parâmetros de produção e de secagem a estudar.

Neste tipo de indústria, a quantidade de produção é um fator de grande importância e a variedade de produtos leva a que, por vezes, no mesmo dia haja várias alterações de produção.

Sendo assim, para caso de estudo, foi escolhida a produção de papel reciclado que ocorre habitualmente durante 5 dias consecutivos.

Outra produção escolhida foi a de 4 ton/h, calculada a partir da equação 3.6, que corresponde à maioria da produção presente na base de dados (Figura 4.18), calculada a partir da gramagem; da velocidade da máquina; e do crepe.

### 4.5.1 Teste Papel Reciclado

Após análise cuidadosa do histórico de produção foi encontrado um padrão — percebeu-se que os parâmetros de secagem escolhidos eram habitualmente constantes para a produção de papel reciclado:

Tabela 4.4: Condições típicas de secagem para produção de papel reciclado

Condições de Secagem		
Pressão Yankee	Temperatura Campânula	rpm Recirculadores
5 bar	270°C	1650 rpm

Contudo, do ponto de vista físico, este tipo de condições serão válidas para qualquer tipo produção desta magnitude:

Tabela 4.5: Condições típicas de produção de papel reciclado

Condições de Produção		
Gramagem	Velocidade da Máquina	Crepe
17g/m <sup>2</sup>	1500m/min	−21.5%

Usando a equação 3.6 obtém-se um valor de cerca de 3,3 ton/h.

Usando a GUI com os dados enunciados anteriormente, e considerando que o teor de humidade no papel à entrada ( $H_{in}$ ) é 60%, foi simulado um valor de TS igual a 4421,4 kgH<sub>2</sub>Oev e um Teor de Humidade de 6,45 %.

Foram testadas várias possibilidades de poupança, no entanto a que se concretizou na realidade foi a simulada no **CASE2**, como ilustrado na figura 4.17.

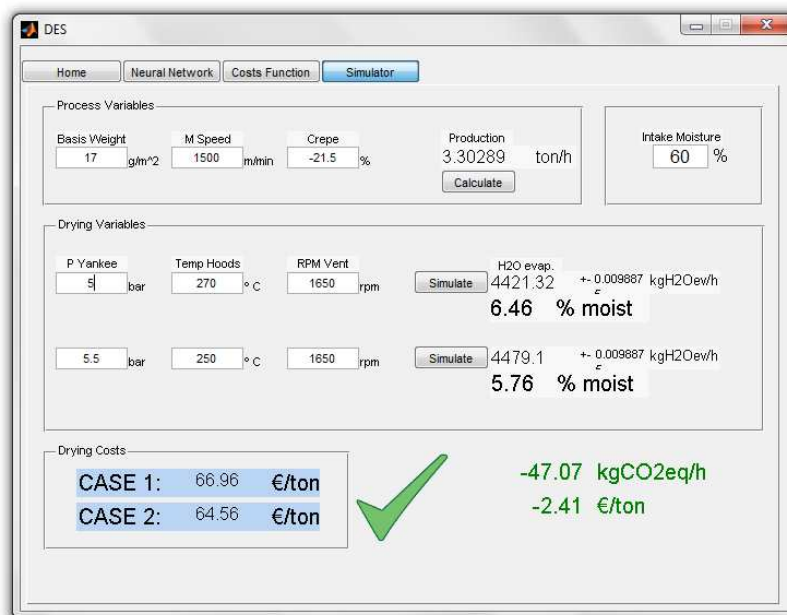


Figura 4.17: Simulação da Proposta de poupança energética para produção de papel reciclado

Nesta proposta de poupança, verifica-se ser possível emitir - 47.07 kg  $CO_2eq/h$  e de acordo com o tarifário energético em vigor, menos 2.41 €/ton. E no entanto, é possível evaporar mais cerca de 58kg  $H_2O$  e prever um teor de humidade de 5.76 %.

Se se tiver em conta que a cada produção deste tipo de papel são produzidas cerca de 400 ton, é prevista uma poupança de cerca de 964€e de cerca de 5.7 ton  $CO_2eq$ .

Esta poupança ocorre sem compromisso com o controlo de qualidade e de forma a validar esta simulação, é possível observar no Apêndice C que as condições escolhidas nesta proposta satisfazem o teor de humidade desejado, isto é o desvio padrão encontrado nos testes igual a 0.47 % para um valor médio de teor de humidade igual a 5.04 %. Uma razão para o valor médio ser díspar do valor simulado é ter-se considerado como valor fixo, o teor de humidade à entrada do processo igual a 60 %.

#### 4.5.2 Teste 4 ton/h

Visto nem sempre ser possível funcionar à velocidade máxima da máquina (i.e. produção máxima), esta produção é aquela cujas ocorrências se verificam mais vezes na base de dados — cerca de 20 %. Pode-se constatar pela Figura 4.18 que a zona mais densa da base de dados é por volta das 4 ton/h.

Deste modo é possível verificar mais uma vez, se a RN tem capacidade de obter valores interessantes onde a densidade do conhecimento é superior.

De acordo com os dados de produção, verificou-se que as condições de secagem, para uma produção desta magnitude eram frequentemente, aquelas expostas na tabela 4.6.

A partir da figura 4.19, é possível verificar, que tais condições de secagem, estão de acordo com o previsto numa operação de secagem —  $\approx 5\%$  para o Teor de Humidade.






Figura 4.18: Histograma da Produção na base de dados

Tabela 4.6: Condições típicas de secagem para produção de 4 ton/h

Condições de Secagem		
Pressão Yankee	Temperatura Campânula	rpm Recirculadores
6.5 bar	360°C	1800 rpm

Ao testar uma situação de poupança (**Case 2**), constatou-se que é possível poupar a emissão de 62.18 kg  $CO_2eq/h$  e o custo de 2.51 €/ton de papel produzido. Esta simulação reflete que apesar do aumento de 100 rpm no Recirculadores e 0.2 bar no Cilindro Yankee, é possível poupar energia térmica advinda dos queimadores da Campânula.

Tendo em conta o paradigma energético português no presente ano, pode-se concluir, que, sempre que possível, manter os ventiladores no máximo possível.

### 4.5.3 Casos Extremos

Um dos objetivos deste trabalho, era tentar perceber, se seria possível desligar, ou manter no mínimo possível, algum dos intervenientes da secagem. Esta abordagem estudará os efeitos na qualidade do papel, e nos custos energéticos. O caso de estudo será manter, ora a Campânula, ora o cilindro *Yankee*, a operar nas condições mínimas admissíveis.

Considere-se o **Case 1** das simulações 4.17 e 4.19 como termo de comparação.

Nota: A simulação não tem comparação com a realidade, e serão admitidos valores passíveis de chumbar nos requisitos de funcionamento do controlo da máquina de papel.

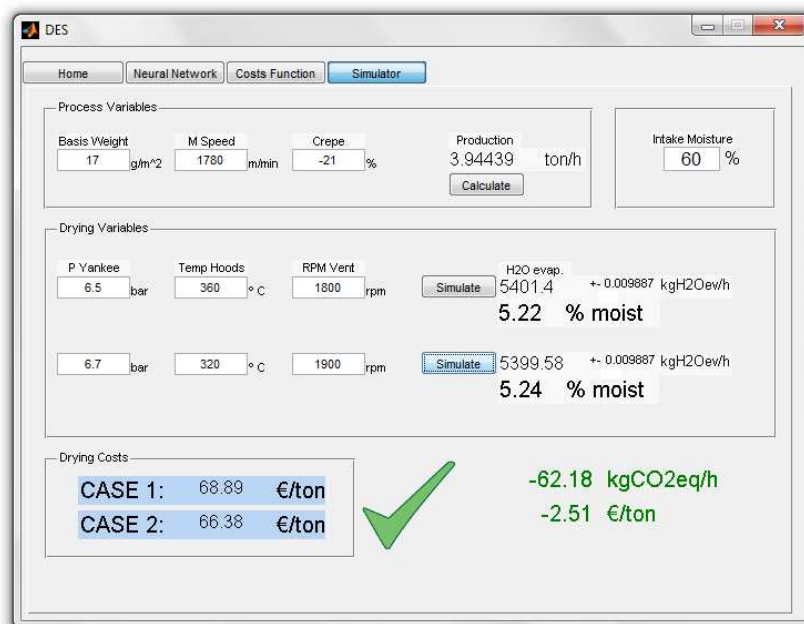


Figura 4.19: Simulação da Proposta de poupança energética para produção de 4 ton/h

Para o caso de se desligar por completo os queimadores, obtém-se a simulação 4.20, onde é considerado que a temperatura de jato é de 40°C e que os ventiladores conseguem operar a 1950 rpm (velocidade máxima atingida na base de dados) a esta temperatura.

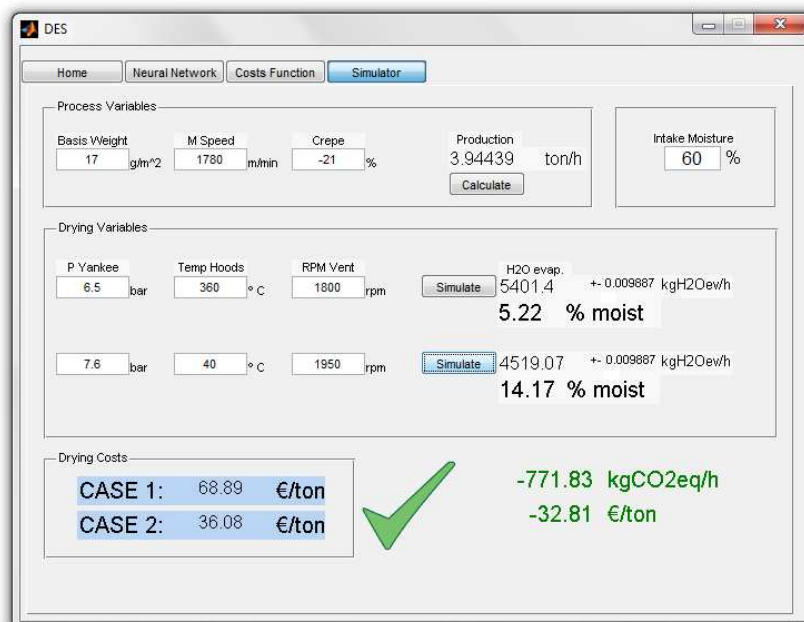


Figura 4.20: Simulação da proposta de condições extremas de funcionamento da secagem, desligando o queimador da Campânula

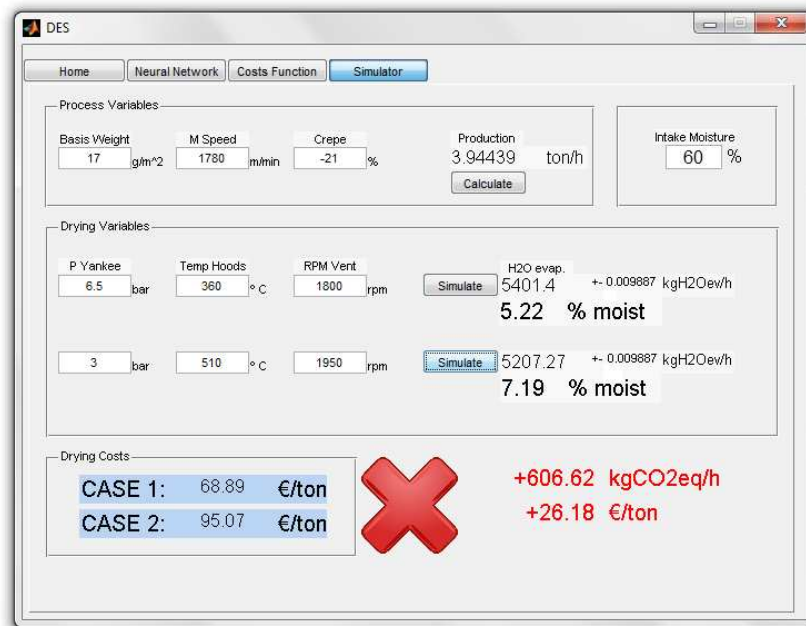


Figura 4.21: Simulação da proposta de condições extremas de funcionamento da secagem, mantendo o cilindro *Yankee* em *stand-by*

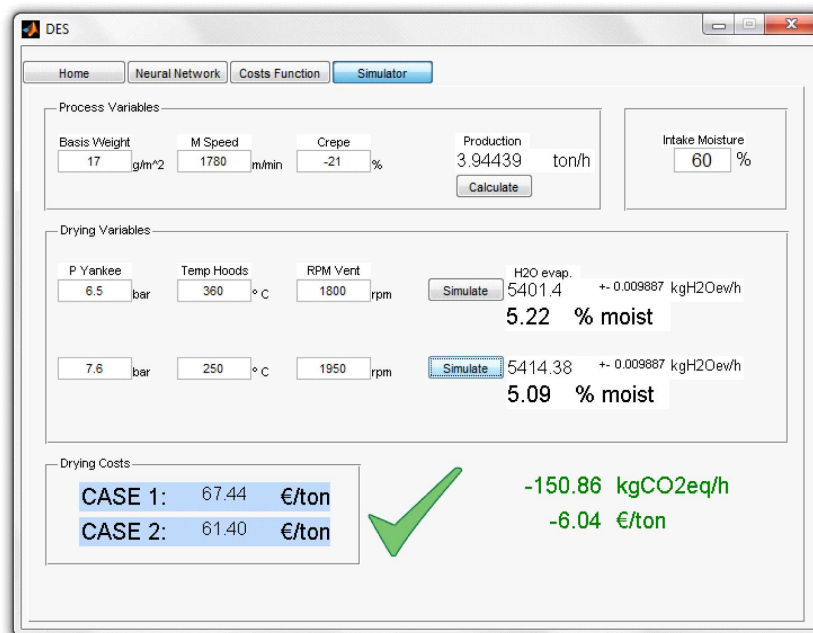


Figura 4.22: Simulação da proposta de condições extremas de funcionamento da secagem, maximizando valores de pressão no cilindro *Yankee*

Como se pode observar na Figura 4.20, mesmo levando a pressão ao máximo registado na base de dados (i.e. 7.6 bar), não existe poder suficiente de secagem de modo a que o

teor de humidade atinja os valores desejados pelo controlo de qualidade. No entanto, é possível poupar uma quantidade significativa de energia.

No caso de se manter o cilindro *Yankee* em valores mínimos, 3 bar, e a Campânula a operar à velocidade máxima de 1950 rpm e temperatura máxima registada de  $510^{\circ}\text{C}$ , obtem-se, a par com a simulação anterior, uma fraca Taxa de Secagem e, consequentemente, um alto teor de humidade.

Como se pode constatar, ao nível de custos relativos à secagem, este caso é muito menos atrativo que o anterior.

Desta forma conclui-se que nenhum interveniente é suscetível de substituir o outro, que é necessário que operem a par, contudo, favorecendo a utilização do cilindro *Yankee*, visto ser mais económico.

Seguindo esta ótica, realizaram-se as simulações 4.22 e 4.23, referentes às simulações 4.20 e 4.21, mas neste caso, foram incrementados os valores de temperatura da Campânula e de pressão do cilindro *Yankee*, respectivamente, de modo a se atingir um valor interessante de teor de humidade. i. e.  $\approx 5\%$ .

Pode-se observar que, comparativamente ao valor de referência para este tipo de produção, é possível poupar a emissão de  $150.86\text{ kg CO}_2\text{eq/h}$  e poupar  $6.04\text{ €/ton}$ .

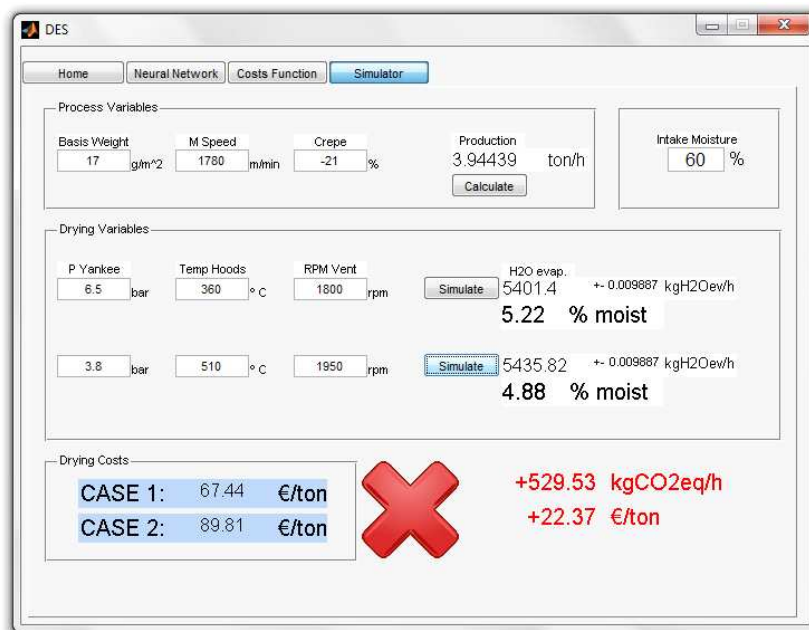


Figura 4.23: Simulação da proposta de condições extremas de funcionamento da secagem, maximizando valores de temperatura da Campânula

Pode-se observar o aumento de custos ambientais e económicos na simulação 4.23. Em relação aos valores padrão, são emitidos  $+ 529.52\text{ kg CO}_2\text{eq/h}$  e por tonelada são dispendidos mais  $22.37\text{ €/ton}$ .

Comparando os dois casos, se se favorecer a temperatura da Campânula em relação à pressão do cilindro *Yankee*, fica mais caro 6.04 €/ton com um aumento de emissões de 680.38 kg  $CO_2eq/h$ .

Comprova-se a necessidade de favorecer a pressão no cilindro *Yankee*, em detrimento da temperatura na Campânula.



## Capítulo 5

# Conclusão e Trabalhos Futuros

### 5.1 Conclusões e Sugestões para Trabalhos Futuros

O objetivo desta dissertação foi alcançado — foi desenvolvido um modelo representativo de secagem de papel *tissue* em Ambiente Industrial. A partir deste, descortinou-se a influência dos intervenientes na secagem e percebeu-se que: O cilindro Yankee é o mais eficiente dos consumidores de gás natural; e que, tendo em conta o paradigma energético atual, a velocidade de rotação dos Recirculadores deve ser maximizada.

Foram revistos modelos de secagem e os fenómenos físicos relativos a estes; foram identificadas as variáveis a ter em conta para o desenvolvimento de um modelo de secagem; e foi estudada a viabilidade do desenvolvimento de um modelo físico.

Cedo se verificou, que, a obtenção de parâmetros de secagem era extremamente dificultada: Num processo industrial não há acesso total para a colocação de sensores em zonas relevantes; é necessário ser oportuno nos testes a realizar; e é conveniente, dispor de uma janela temporal maior do que o período relativo ao desenvolvimento desta dissertação.

Deste modo, optou-se por desenvolver tal modelo, recorrendo a Redes Neurais. Verificou-se que é possível representar um processo, sem que para isso seja necessário ter acesso às variáveis mandatórias para um modelo físico. Isto é, um modelo pode ser criado, caso haja acesso a variáveis diretamente correlacionadas com as referidas.

A flexibilidade advinda da utilização do conceito de redes neurais, facilita a modelação em ambiente industrial. No entanto, tratando-se de um método eurístico, é necessária cautela na colecção de informação para alimentar o modelo.

Neste tipo de modelos, a qualidade da base de dados, está fortemente relacionada com a qualidade final do modelo. Uma base de dados, com informação duvidosa, ou ambígua, provavelmente levará a que a aprendizagem da rede neuronal seja comprometida. Relações causa-efeito em situações cujas relações não são verificadas, confusão da rede neuronal com diferentes efeitos para a mesma causa, e perda da capacidade de analisar novos elementos fora da zona de conforto (i.e. fora da base de dados), são exemplos do que pode acontecer com uma base de dados de fraca qualidade.

O caso de estudo na empresa AMS-Gomá Camps, permitiu que valores reais do funcionamento de uma Máquina de Papel *tissue*, alimentassem a base de dados. Embora os métodos laboratoriais de determinação do teor de humidade, e de recolha de informação, se revelem de certa forma obsoletos, a qualidade da base de dados demonstrou ser suficiente para a criação de um modelo representativo da secagem.

Na análise de funcionamento da aplicação em MATLAB®, foram encontrados valores extremos de poupança, seria de todo o interesse que tais valores fossem passíveis de ser testados.

Verificou-se não haver acesso a variáveis importantíssimas para descrição do processo, em especial atenção para o teor de humidade no início do processo de secagem —  $H_{Yanke}$ . Para este parâmetro, foi necessário desenvolver um método matemático-empírico, de forma a que, o modelo se pudesse comportar de acordo com o esperado para um processo de secagem. Verificou-se que, a falta deste parâmetro levava a que a rede neuronal revelasse um comportamento contranatura.

O modelo revela uma certeza extrema na determinação de valores de Taxa de Secagem, quer no conjunto de valores de treino, quer nos valores de validação e de teste. Esta certeza, revela a capacidade das redes neuronais em modelar sistemas complexos e não lineares.

Para o caso deste trabalho, é provável que a ingenuidade acerca do tema, tenha levado a tomar considerações desajustadas. Assim sendo, é provável que, com um conhecimento mais maduro poder-se-á atingir resultados mais interessantes.

Foi desenvolvido um modelo de consumos, que, apesar de obter valores de convergência bastante aceitáveis, não foi devidamente validado. Isto é, o período de recolha de dados incidu em apenas numa janela temporal de 3 meses consecutivos do ano.

Não sendo variáveis presentes nesta base de dados: a temperatura do ar exterior; a concentração de  $O_2$  na atmosfera; e a Humidade relativa. É provável que o modelo perca alguma representatividade fora desta janela temporal. Assim, é pertinente realizar testes de validação de modo a que o modelo seja mais fidedigno em qualquer altura do ano.

A obtenção dos dados, foi possível através do registo manual de vários parâmetros em simultâneo, o que não invalida a presença de erro humano. Foram realizadas regressões desses valores de modo a obterem-se curvas de consumo para cada parâmetro de secagem. Seria interessante, desenvolver um método informático de modo a que, os dados registados nos *dataloggers* fossem registados na base de dados, em simultâneo com os dados presentes no *software* de controlo da Máquina de Papel, em particular, ou de outro equipamento, em geral, caso o estudo incida sobre um campo transversal à indústria papelreira.

Com o desenvolvimento do modelo do consumo energético relativo à secagem de papel *tissue*, percebeu-se a potencialidade das redes neuronais na modelação e aplicação de redes neuronais em modelação de sistemas energéticos. Percebeu-se que, apesar de se ter insistido na optimização da arquitectura da Rede Neuronal, qualquer uma delas, provavelmente, se comportasse de forma mais convergente, do que um modelo puramente físico.

Tanto na óptica académica, como na industrial, seria extremamente interessante, que, fossem criadas bases de dados provenientes de outros processos consumidores de energia. Caso os processos, fossem descritos nos mesmos moldes dos presentes nesta dissertação (i.e. 4 inputs e 1 output), experimentar-se-ia desenvolver um modelo representativo, através da arquitectura da Rede Neuronal já otimizada no presente trabalho.

De modo a facilitar a implementação do modelo a novas realidades de produção, foi desenvolvida uma ferramenta informática através do MATLAB®. Esta ferramenta permite: carregar a base de dados que irá alimentar a Rede Neuronal; criar e treina-la de acordo com a arquitectura optimizada. Após introdução das curvas de consumo relativas



às variáveis a modelar, é possível simular diferentes cenários. A partir da ferramenta, poder-se-ão comparar diferentes parâmetros e actuar no sentido da eficiência energética.

É possível, sem elevado custo adicional, modificar o *layout* da aplicação, de modo a esta se adaptar a outras realidades para lá da indústria de papel *tissue*.



# Bibliografia

- [1] Gabrielli R, Medeot C, Miconi D. Energy saving in the tissue industry: technical and economic aspects of a case study. Università di Pisa, Dipartimento di Energetica, Facoltà di Ingegneria, via Diotisalvi, 2, Pisa 56126, Italy; 2005.
- [2] Mujumdar AS, Devahastin S. FUNDAMENTAL PRINCIPLES OF DRYING; 2000.
- [3] Demuth H, Beale M. Neural Network Toolbox; 2002.
- [4] Lertworasirikul S, Tipsuwan Y. Moisture content and water activity prediction of semi-finished cassava crackers from drying process with artificial neural network. Journal of Food Engineering. 2008;84:65 – 74.
- [5] Duncan S. Transactions of the Institute of Measurements and Control. 2003;25:1 – 2.
- [6] Salama SY, Minsker BS, Olsen KG. Competitive Position of Natural Gas: Industrial Solids Drying, Energy and Environmental Analysis. Inc., Arlington, VA; 1987.
- [7] Slätteke O. Modeling and Control of the Paper Machine Drying Section. Lund , Sweden; 2006.
- [8] Eskelinen PJ. How to improve the paper machine performance by combining dryer section survey and computer simulation. Drying Technology. 1985;3:255 – 269.
- [9] Organization UNID. Industrial Development Report 2011, Industrial energy efficiency for sustainable wealth creation. United Nations; 2011.
- [10] Culicchi P. L'industria cartaria italiana e il contesto europeo. In: Third Workshop Comieco- MIAC (in Italian language). Lucca; 2002. .
- [11] Radek C, Mingyong C, Modi V, West AC. High Schmidt mass transfer in a turbulent impinging slot - jet flow. International Journal of Heat and Mass Transfer. 2011;2001:3775 – 3785.
- [12] Kamyar M, Maryam N. Modeling of tomato drying using artificial neural network. Computers and Electronics in Agriculture. 2007;59:78 – 85.
- [13] Bond JF. Drying Paper by Impinging Jets of Superheated Steam: Drying Rates and Thermodynamic Cycles. Mc Gill University, Montréal; 1991.
- [14] Weineisen H, Stenström S. MODELING THROUGH DRYING OF TISSUE - EFFECT OF PORE SIZE DISTRIBUTION ON DRYING CHARACTERISTICS. In: Proceedings of the 14th International Drying Symposium. vol. A; 2004. p. 397–404.

- 
- [15] Lescanne P, Perré Y, Brocard Y. MODELLING OF PAPER DRYING: A COMPREHENSIVE COMPUTATIONAL MODEL USED BY THE INDUSTRY. In: Proceedings of the 14th International Drying Symposium; 2004. .
- [16] Weineisen H, Stenström S. A Model for Through Drying of Tissue Paper at Constant Pressure Drop and High Drying Intensity. Drying Technology. 2007;25(12):1949–1958. Available from: <http://www.tandfonline.com/doi/abs/10.1080/07373930701727259>.
- [17] Lu T, Shen SQ. Numerical and experimental investigation of paper drying: Heat and mass transfer with phase change in porous media. Applied Thermal Engineering. 2007;27:1248 – 1258.
- [18] Vieira MGA, Rocha SCS. Drying conditions influence on physical properties of recycled paper. Chemical Engineering and Processing. 2007;46:955 – 963.
- [19] Fine TL. Feedforward Neural Network Methodology. Springer; 1999.
- [20] Jindal VK, Chauhan V. Neural networks approach to modeling food processing operation. Food processing operations modeling: design and analysis. 2001;p. 305 – 342.
- [21] Press W, Flannery B, Teukolsky S, Vetterling W. Numerical Recipes in C: The Art os Scientific Programming. Cambrige Univ.; 1992.
- [22] Hecht-Nielsen R. Theory of the Backpropagation Neural Network. In: Proceedings of the International Joint Conference on Neural Networks. Washington: IEEE Publications, NY; 1989. p. 593 – 605.
- [23] DESPACHO n.º 17313 / 2008. Diário da República, 2ª Série. 26 de Junho de 2008;N.º 122.

# Parte IV

## Apêndices



## Apêndice A

### Recolha de amostras de $H_{Yankeee}$

Este anexo é referente à recolha de amostras de teor de humidade no início do processo de secagem —  $H_{Yankeee}$ .

A recolha deste tipo de amostras é de extrema dificuldade, é necessário o uso de uma ferramenta específica para o efeito, bem como destreza para realização de tal tarefa. O local de amostragem, está representado na figura A.1 e é possível observar que se trata de uma zona de difícil acesso.




Figura A.1: Representação da zona de amostragem

Tabela A.1: Teste de *seccitate* da Prensa

<b>Secura (%)</b>	<b><math>H_{Yanke}</math></b>
40	60
38	62
37	63
38	62
37	63
39.7	60.3
40.5	59.5
39.9	60.1
39.7	60.3
38.2	61.8
36.2	63.8
39.9	60.1
40.3	59.7

Foram retiradas amostras em produções de diferente carácter e verificou-se que a média de Teor de Humidade no início do processo de secagem é de 61.2 %, máximo de 63.8 % e mínimo de 59.5 %.



## Apêndice B

# Simulações de comportamento do Modelo de Secagem para diferentes valores de Produção

### B.1 Produção de 4 ton/h




Figura B.1: Comportamento do Modelo de Secagem variando a pressão do cilindro *Yankee* a 4 ton/h de produção




Figura B.2: Comportamento do Modelo de Secagem variando a temperatura da Câmpula a 4 ton/h de produção




Figura B.3: Comportamento do Modelo de Secagem variando a velocidade dos Recirculadores a 4 ton/h produção

## B.2 Produção de 4.6 ton/h




Figura B.4: Comportamento do Modelo de Secagem variando a pressão do cilindro *Yankee* a 4.6 ton/h de produção




Figura B.5: Comportamento do Modelo de Secagem variando a temperatura da Câmpula a 4.6 ton/h de produção




Figura B.6: Comportamento do Modelo de Secagem variando a velocidade dos Recirculadores a 4.6 ton/h produção

## Apêndice C

# Base de dados relativa ao teste com papel reciclado

Tabela C.1: Teste com papel reciclado

<b>pressão Yankee</b>	<b>Temp. Campânula</b>	<b>RPM Recirculadores</b>	<b><math>g/m^2</math></b>	<b>Velocidade MP</b>	<b>Crepe</b>	<b><math>H_{LAB}</math></b>
5	255	1750	17.4	1500	-21.5	5.2
5	255	1700	17.2	1500	-21.5	5.3
5	255	1700	17.2	1500	-21.5	5.3
5	255	1700	17.3	1500	-21.5	6.3
5.2	255	1700	17.4	1500	-21.5	6
5.2	255	1700	17.3	1500	-21.5	4.8
5.2	255	1700	17.4	1500	-21.5	3.5
5.2	255	1650	17.4	1500	-21.5	4.8
5.2	255	1650	17.5	1500	-21.5	4.3
5.2	255	1650	17.5	1500	-21.5	5.5
5.5	250	1650	17.5	1500	-21.5	4.9
5.5	250	1650	17.4	1500	-21.5	5.1
5.5	250	1650	17.5	1500	-21.5	5.3
5.5	250	1650	17.4	1500	-21.5	5.3
5.5	250	1650	17.5	1500	-21.5	4.2
5.5	250	1650	17.5	1500	-21.5	4.3
5.5	250	1650	17.0	1500	-21.5	5.2
5.5	250	1650	17.4	1500	-21.5	5
5.5	250	1650	17.5	1500	-21.5	5.6
5.5	250	1650	17.5	1500	-21.5	5.5

De interesse para o teste de papel reciclado, cingiu-se apenas nas variáveis que revelavam uma poupança interessante, e ao mesmo tempo, aquelas cuja janela temporal de produção foi a mais alargada.

Tabela C.2: Condições de secagem no **CASE 2**

<b>pressão Yankee</b>	<b>Temp. Campânula</b>	<b>RPM Recirculadores</b>	$H_{LAB}$
5.5	250	1650	4.9
5.5	250	1650	5.1
5.5	250	1650	5.3
5.5	250	1650	5.3
5.5	250	1650	4.2
5.5	250	1650	4.3
5.5	250	1650	5.2
5.5	250	1650	5
5.5	250	1650	5.6
5.5	250	1650	5.5

As condições do **Case 2** revelam que a amostragem de  $H_{LAB}$  tem uma média de valores de 5.04 %, um valor máximo de 5.6 %, um mínimo de 4.2 % e um desvio padrão de 0.47 %.